


**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**  
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKACNÍCH  
TECHNOLÓGIÍ**  
**ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ**  
FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION  
DEPARTMENT OF BIOMEDICAL ENGINEERING

## DETEKCE ISCHEMIE V EKG ZÁZNAMECH

DETECTION OF ISCHEMIA IN ECG

**DIPLOMOVÁ PRÁCE**  
MASTER'S THESIS


**AUTOR PRÁCE**  
AUTHOR

**Bc. PAVEL TICHÝ**

**VEDOUCÍ PRÁCE**  
SUPERVISOR

**Ing. MARINA RONZHINA**

BRNO 2014



**VYSOKÉ UČENÍ  
TECHNICKÉ V BRNĚ**

**Fakulta elektrotechniky  
a komunikačních technologií**

**Ústav biomedicínského inženýrství**

# Diplomová práce

Magisterský navazující studijní obor  
**Biomedicínská technika a bioinformatika**

**Student:** Bc. Pavel Tichý  
**Ročník:** 2

**ID:** 119751  
**Akademický rok:** 2013/2014

**NÁZEV TÉMATU:**

**Detekce ischemie v EKG záznamech**

## POKYNY PRO VYPRACOVÁNÍ:

1) Provedte literární rešerši v oblasti automatické detekce ischemických úseků v EKG záznamech. Popište parametry EKG a detekční metody, které lze pro tento účel použít. 2) Seznamte se s databází experimentálních zvířecích EKG signálu dostupnou na ÚBMI. Provedte výpočet různých parametrů P-QRS-T segmentu vybraných z několika fází experimentu. 3) Na základě statistické analýzy určete parametry vhodné pro následnou automatickou detekci ischemie. 4) Navrhněte detektor ischemických úseků za použití vypočtených parametrů EKG. Navržený postup realizujte v prostředí Matlab. 5) Zhodnoťte účinnost použití vybrané detekční metody pro řešení daného problému. Porovnejte výsledky s dostupnými údaji z literatury. 6) Provedte diskusi získaných výsledků.

## DOPORUČENÁ LITERATURA:

- [1] ŠTEJFA, Miloš, Josef ŠUMBERA a Pavel BRAVENÝ. Základy elektrokardiografie. Brno: Masarykova univerzita, fakulta lékařská, 1991, 147 s. ISBN 80-210-0265-4.  
[2] CLIFFORD, Gari D, Francisco AZUAJE a Patrick MCSHARRY. Advanced methods and tools for ECG data analysis. Boston: Artech House, 2006, 384 s. ISBN 1-58053-966-1.

**Termín zadání:** 10.2.2014  
**Vedoucí práce:** Ing. Marina Ronzhina

**Termín odevzdání:** 23.5.2014

**prof. Ing. Ivo Provazník, Ph.D.**  
*Předseda oborové rady*

## UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku c.40/2009 Sb.

## **ABSTRAKT**

V této práci jsou popsány projevy ischemie srdce v EKG signálu a shrnuty některé metody umožňující automatickou detekci ischemie. Dále byly vypočteny morfologické parametry EKG ze záznamů dostupných na UBMI a provedeno jejich statistické zhodnocení pro následnou automatickou klasifikaci. Pro vlastní klasifikaci srdečních cyklů byla použita vícevrstvá neuronová síť vytvořená v Matlabu. Na dostupných datech bylo dosaženo úspěšnosti klasifikace až 99,9%.

## **KLÍČOVÁ SLOVA**

Ischemie, morfologické parametry EKG, neuronová síť, klasifikace, analýza hlavních komponent

## **ABSTRACT**

This paper describes the manifestations of ischemia in the ECG signals and summarizes some methods allowing automatic detection of ischemia. Morphological features were then calculated from ECG signals available from UBMI and statistically evaluated to select features appropriate for further automatic classification. Multilayer feedforward neural network was used for classification of heart beats. The neural network was designed in Matlab. Classification performance up to 99.9% was obtained on available dataset.

## **KEYWORDS**

Ischemia, morphological features of ECG, neural network, classification, principal component analysis

### **Bibliografická citace:**

TICHÝ, P. *Detekce ischemie v EKG záznamech*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2014. 77 s. Vedoucí diplomové práce Ing. Marina Ronzhina.

## Prohlášení

Prohlašuji, že svou diplomovou práci na téma Detekce ischemie v EKG záznamech jsem vypracoval(a) samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor(ka) uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této práce jsem neporušil(a) autorská práva třetích osob, zejména jsem nezasáhl(a) nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne .....

.....  
podpis autora (autorky)

## Poděkování

Děkuji vedoucímu semestrální práce Ing. Marině Ronzhině, za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne .....

.....  
podpis autora

# Obsah

1. Úvod.....	9
2. Elektrokardiografie.....	10
2.1. Snímání EKG signálu.....	11
2.1.1. Standardní 12 svodový systém.....	11
2.1.2. Ortogonální svodový systém.....	12
2.2. EKG křivka .....	14
3. Projevy ischemie v EKG signálu .....	16
3.1. Morfologické změny .....	16
3.1.1. T vlna.....	16
3.1.2. ST segment.....	17
3.1.3. Arytmie spojované s akutní srdeční ischemií.....	17
3.2. Nemorfologické změny .....	17
4. Automatická detekce ischemie.....	19
4.1. Získání a předzpracování dat.....	19
4.2. Vytvoření vektoru klasifikačních příznaků .....	20
4.2.1. Morfologické parametry.....	20
4.2.2. Frekvenční analýza.....	21
4.2.3. Časově-frekvenční analýza .....	22
4.2.4. Analýza variability srdečního rytmu .....	23
4.2.5. Analýza hlavních komponent.....	24
4.3. Klasifikace.....	26
4.3.1. Lineární diskriminační analýza .....	26
4.3.2. Shluková analýza.....	26
4.3.3. Umělé neuronové sítě.....	26
4.4. Křížová validace.....	30
4.5. Hodnocení klasifikační účinnosti .....	31
4.6. Přehled nejčastěji používaných klasifikačních metod.....	32
5. Automatická detekce ischemie v experimentálních datech.....	34
5.1. Popis experimentálních dat .....	34
5.2. Vytvoření vektoru klasifikačních příznaků .....	36
5.3. Statistické zhodnocení příznaků.....	38
5.3.1. Testování normality dat.....	38
5.3.2. Srovnání hodnot parametrů kontrolní fáze vs. ischemie .....	38
5.3.3. Testování rozdílů mezi kontrolní a ischemickou fází .....	42
5.3.4. Korelace mezi parametry .....	44
5.3.5. Rozdíly hodnot parametrů mezi různými zvířaty.....	47
5.4. Použitý klasifikátor .....	50
5.5. Výsledky klasifikace a diskuse dosažených výsledků .....	53
5.5.1. Morfologické parametry.....	53
5.5.2. Hlavní komponenty vypočtené z morfologických parametrů .....	54
6. Závěr.....	58
7. Literatura .....	60
Seznam příloh.....	63

## Seznam obrázků

Obr. 1: Elektrický převodní systém srdce [2].....	11
Obr. 2: Bipolární končetinové svody.....	12
Obr. 3: Zapojení unipolárních končetinových svodů.....	13
Obr. 4: Umístění unipolárních hrudních svodů [5].....	13
Obr. 5: Frankův ortogonální svodový systém [4].....	14
Obr. 6: EKG křivka.....	15
Obr. 7: Změny T vlny [7].....	18
Obr. 8: Deprese ST segmentu (svod V2) [6].....	18
Obr. 9: Obecné schéma automatické detekce ischemie.....	20
Obr. 10: Výkonové spektrum normálního EKG signálu [9].....	22
Obr. 11: Projevy arytmií ve výkonovém spektru (PSD) EKG [9].....	22
Obr. 12: Realizace třístupňové dyadické DTWT bankou oktařových filtrů s podvzorkováním[18].....	23
Obr. 13: Schéma třístupňové rychlé DTWT [18].....	24
Obr. 14: Jednoduchý perceptron.....	27
Obr. 15: Aktivační funkce: skoková(a), lineární(b) a sigmoidní(c).....	28
Obr. 16: Klasifikace do dvou tříd (A, B) jedním perceptronem [23].....	28
Obr. 17: Dopředná neuronová síť s jednou skrytou vrstvou.....	29
Obr. 18: Chyba sítě v závislosti na počtu epoch učení.....	30
Obr. 19: K-fold křížová validace.....	32
Obr. 20: Langendorffův perfúzní systém a schéma umístění měřicích elektrod [22].....	35
Obr. 21: EKG průběhy – kontrola (svod X).....	36
Obr. 22: EKG průběhy – ischemie (svod X).....	36
Obr. 23: Znázornění parametrů QJ, QT, JT, ST10, ST20, ST30, ST40, ST50, jTamp a Tamp .....	38
Obr. 24: Znázornění parametrů AUCqrst, AUCqrs, +AUCqrs, -AUCqrs, AUCst-t, AUCsTamp a AUCTampTend.....	39
Obr. 25: Krabicové grafy parametrů QJ, QT a JT.....	40
Obr. 26: Krabicový graf parametru JTamp (svod X).....	40
Obr. 27: Krabicový graf parametru Tamp (svod X).....	41
Obr. 28: Krabicové grafy parametrů ST10, ST20, ST30, ST40, ST50 (svod X).....	41

Obr. 29: Krabicové grafy parametrů AUCqrst, AUCqrs, AUCst-t, +AUCqrs a -AUCqrs (svod X).....	41
Obr. 30: Krabicové grafy parametrů AUCsTamp, AUCTampTend (svod X).....	42
Obr. 31: Krabicové grafy parametrů +/-AUCqrs a sTamp/TendAUC (svod X).....	42
Obr. 32: Krabicové grafy parametrů CEAggrad $\alpha$ , CEAgqr $\alpha$ a CEAsT-t $\alpha$ .....	42
Obr. 33: Krabicové grafy parametru CEAlenght grad.....	43
Obr. 34: Krabicové grafy hodnot parametru QJ pro různé králíky – kontrolní fáze.....	48
Obr. 35: Krabicové grafy hodnot parametru QJ pro různé králíky – ischemická fáze.....	49
Obr. 36: Krabicové grafy hodnot parametru ST20 (svod X) pro různé králíky – kontrolní fáze.....	49
Obr. 37: Krabicové grafy hodnot parametru ST20 (svod X) pro různé králíky – ischemická fáze.....	49
Obr. 38: Krabicové grafy hodnot parametru Tamp (svod X) pro různé králíky – kontrolní fáze.....	50
Obr. 39: Krabicové grafy hodnot parametru Tamp (svod X) pro různé králíky – ischemická fáze.....	50
Obr. 40: Vývojový diagram – klasifikace s využitím všech parametrů EKG.....	51
Obr. 41: Vývojový diagram – klasifikace s využitím analýzy hlavních komponent.....	52
Obr. 42: Chyba sítě v závislosti na počtu epoch učení: a) traingd b) traingda.....	53
Obr. 43: Scree plot.....	55



# 1. Úvod

Elektrokardiografie patří mezi základní a nejpoužívanější diagnostické metody. Záznam elektrické aktivity srdce – elektrokardiogram (EKG) poskytuje velké množství cenných informací o funkci a stavu srdce.

Ischemie srdce, která vzniká nepoměrem mezi poptávkou a dodávkou kyslíku, je jedním ze závažných stavů, které lze z elektrokardiogramu diagnostikovat.

Analýza EKG záznamu se provádí nejčastěji manuálně, avšak byla vytvořena řada metod umožňující automatickou analýzu EKG záznamu, např. detekci ischemie.


Automatická detekce ischemie zahrnuje výpočet vytvoření vektoru klasifikačních příznaků a následnou klasifikaci vhodným klasifikátorem. Tento vektor klasifikačních příznaků může být tvořen morfologickými nebo nemorfologickými parametry EKG. Morfologické parametry určují přímo z úseků EKG křivky a jedná se parametry jako je šířka QRS komplexu, amplituda T vlny, amplituda ST úseku apod. Naproti tomu nemorfologické parametry mohou být získány např. vlnkovou transformací EKG signálu, analýzou hlavních komponent, využitím parametrů popisujících variabilitu srdečního rytmu (HRV), atd. Vhodným klasifikátorem pak mohou být např. umělé neuronové sítě, algoritmus podpůrných vektorů (SVM), shluková analýza a další. Některé metody umožňující automatickou detekci ischemie jsou v této práci blíže popsány. Žádná z těchto metod však zatím není zcela spolehlivá. Výstupem všech těchto metod je zařazení analyzovaných úseků EKG signálů do kategorie ischemický nebo neischemický.

Praktická část této práce je věnována statistickému zhodnocení vypočtených morfologických parametrů EKG a návrhu a testování vhodného klasifikátoru v prostředí Matlab.

## 2. Elektrokardiografie

Elektrokardiografie je základní vyšetřovací metoda v kardiologii založená na snímání elektrické aktivity srdečního svalu a jejím záznamu ve formě elektrokardiogramu. Elektrická aktivita je podmínkou mechanické činnosti srdce, a proto má elektrokardiografie důležitou diagnostickou roli u řady srdečních chorob. Jejím principem je snímání elektrické srdeční aktivity pomocí elektrod umístěných většinou na kůži pacienta. Umístění snímacích elektrod je zpravidla normalizováno. [1] [2]

Impuls pro kontrakci myokardu vzniká v tzv. sinoatriálním (SA) uzlu v oblasti pravé předsíně. Sinoatriální uzel má schopnost vytvářet elektrické impulsy díky svalovým buňkám, které se nazývají kardiomyocyty. Tyto buňky mají schopnost generovat elektrické impulsy. Impulsy se šíří více dráhami do předsíně až k atrioventrikulárnímu (AV) uzlu a způsobí jejich podráždění a následnou kontrakci. Dále přechází elektrický impuls na Hisův svazek, to je jediná možná cesta, kterou vzruch může přejít na komory, protože okolní síňokomorové rozhraní je tvořeno zcela nevodivou vazivovou tkání. Elektrický impuls prochází následně Tawarovými raménky, až do sítě Purkyňových vláken, takže dochází k rychlému podráždění obou komor v celém jejich rozsahu, což vyvolá mechanickou kontrakci obou komor. Obrázek č.1 zobrazuje tento elektrický převodní systém srdce. [1],[2],[3]



Obr. 1: Elektrický převodní systém srdce [2]

## 2.1. Snímání EKG signálu


Slabé elektrické biosignály vznikající při činnosti srdce se šíří tělem až k jeho povrchu. Proto je možné tyto signály snímat pomocí elektrod umístěných na povrchu těla. Jedná se tedy o neinvazivní vyšetření. Invazivní měření, tedy snímání přímo z povrchu srdce se provádí pouze ve výjimečných případech. Rozmístění elektrod na povrchu těla je normalizováno. Existuje několik různých svodových systémů. [1],[3]

### 2.1.1. Standardní 12 svodový systém

Standardní 12 svodový systém je zdaleka nejrozšířenější. Využívá 10 elektrod rozmístěných na končetinách a hrudníku. V tomto systému existují 3 typů svodů[3]:

#### Bipolární končetinové svody - I, II, III

Bipolární (Einthovenovy) končetinové svody označované římskými číslicemi I až III jsou bipolární svody, které měří napětí vždy mezi dvěma body na těle. Svod I snímá napětí mezi pravou (R) a levou (L) rukou, svod II napětí mezi pravou rukou (R) a levou nohou (F) a svod III napětí mezi levou rukou (L) a levou nohou (F). Schématický náčrt bipolárních končetinových svodů je na Obr. 2. [3]




Obr. 2: Bipolární končetinové svody

#### Unipolární končetinové svody - aVL, aVR, aVF

Unipolární (Goldbergerovy) svody využívají vždy všech tří končetinových měřicích elektrod. Napětí je snímáno mezi jednou z končetin a průměrnou hodnotou napětí mezi zbývajících dvěma elektrodami vytvořenou spojením obou zbývajících elektrod přes odpory o


velikosti  $5\text{ k}\Omega$ . Malé  $a$  v jejich názvu znamená augmentované (navýšené) napětí. Zapojení unipolárních končetinových svodů je na Obr. 3. [3]



Obr. 3: Zapojení unipolárních končetinových svodů

### Unipolární hrudní svody - V1, V2, V3, V4, V5, V6

Unipolární hrudní svody na rozdíl od končetinový snímají elektrickou aktivitu srdce v horizontální rovině. Napětí těchto svodů je snímáno vůči *indiferentní* svorce vytvořené spojením všech končetinových elektrod a měřicí elektrodě (V1 – V6). Hrudní elektrody jsou někdy označovány také C1 – C6. [3]




Obr. 4: Umístění unipolárních hrudních svodů [5]

#### 2.1.2. Ortogonální svodový systém

Ortogonální (provoúhlý) svodový systém snímá elektrickou aktivitu srdce ze tří na sebe kolmých rovin ( $x$ ,  $y$ ,  $z$ ). Tento svodový systém je vhodný pro vytváření vektorkardiogramu. Ortogonální svodový systém je klinické praxi málo využívaný, ale je využíván v experimentální kardiologii např. při měření na izolovaném srdci. [3]

Tvar hrudníku znemožňuje vhodné umístění elektrod, proto byly vytvořeny systémy, které průměrují signál z většího počtu elektrod pomocí odporové sítě, např. Frankův (viz Obr. 2). [4]


Při měření na izolovaných zvířecích srdcích mohou být snímací elektrody umístěny např. na stěnách nádoby, ve které je srdce umístěno.



Obr. 5: Frankův ortogonální svodový systém [4]

## 2.2. EKG křivka

Každá část EKG křivky reprezentuje určitou mechanickou činnost srdce. V EKG křivce rozeznáváme charakteristické vlny (vlny P, T), kmity (Q, R, S) a úseky (PR, ST atd.) a intervaly (PR, QT). Na základě jejich amplitud a doby trvání lze určit informace o zdravotním stavu srdce.



Obr. 6: EKG křivka [3]

- *P vlna* - je projevem depolarizace pravé a levé srdeční síně. Doba trvání této vlny je až 120 ms a maximální výška do 300  $\mu$ V.
- *P-R interval* - začíná depolarizací síní a končí depolarizací komor. Je dán časem, který potřebuje signál z SA uzlu k cestě do srdečních komor.
- *PR segment* - izoelektrický úsek od konce P vlny po začátek QRS komplexu.
- *Q kmit* - má negativní výchylku typickou dobu trvání asi 30 ms.
- *R kmit* - následuje po Q kmitu. Dosahuje amplitudy asi 1 mV. Doba trvání je do 100 ms.
- *S kmit* - má stejně jako Q kmit negativní výchylku. Doba trvání je maximálně 50 ms.
- *QRS komplex* - skládá se z kmitů Q, R a S. Je projevem depolarizace srdečních komor. Souběžně probíhající depolarizace síní je překryta mnohem silnějším signálem depolarizace komor. Typická délka trvání je mezi 60 – 120 ms.
- *Bod J* - nachází se na konci QRS úseku. Bývá izoelektrický.
- *ST segment* - je izoelektrický úsek mezi koncem QRS komplexu a počátkem T vlny. Reprezentuje čas, po který jsou aktivovány komory.
- *QT interval* - je časový úsek od počátku QRS komplexu po konec T vlny. Odpovídá času od počátku depolarizace srdečních komor po konec jejich repolarizace. Délka

tohoto intervalu je závislá na srdečním rytmu, se zrychlující se činností srdce se zkracuje.

- *T vlna* - je projevem depolarizace srdečních komor. Doba trvání je mezi 100 až 250 ms.
- *RR interval* - úsek mezi dvěma R kmity představuje dobu celého srdečního cyklu. Detekce tohoto úseku má velké využití od měření tepové frekvence po měření variability srdečního rytmu (HRV).

V EKG se mohou objevovat následující typy rušení a artefakty, které brání spolehlivému popisu EKG křivky[3]:

- *Kolísání nulové linie (drift)* - je důsledkem pomalých elektrochemických dějů na rozhraní elektroda – kůže, dýchání (cca 0,8 Hz) a pohybu pacienta (do 2 Hz). Odstranění tohoto artefaktu se provádí např. pomocí lineárního filtru horní propust s mezním kmitočtem asi 0,7 Hz. U analogových filtrů se doporučuje dolní mezní kmitočet 0,05 Hz, důvodem je nelineární fázová charakteristika těchto filtrů, která je přibližně lineární až od zmíněných asi 0,7 Hz.
- *Rušení síťovým kmitočtem* - vzniká v důsledku indukce napětí ze silových elektrických rozvodů. Projevuje se na frekvenci 50 Hz (Evropa) nebo 60 Hz (USA, Japonsko). Síťové rušení je harmonický signál, který se prolíná se spektrem užitečného signálu. Toto rušení se v EKG signálu často objevuje, pokud není zajištěn dostatečně nízký přechodový odpor mezi měřicí elektrodou a kůží. Odstraňuje se lineárním filtrem typu úzkopásmová zádrž.
- *Myopotenciály* - vznikají při činnosti svalů vyšetřovaného pacienta. Odstranění těchto artefaktů je obtížné, protože jich spektrum se prolíná se spektrem užitečného signálu. Projevuje se frekvencích vyšších než 10 Hz (zátěžové EKG) nebo vyšších než 100 Hz (klidové EKG). K jeho odstranění lze použít lineární filtr typu dolní propust s mezní frekvencí cca 45 Hz, je ale potřeba počítat s určitým zkreslením jako je ořezání QRS komplexu. Lepší výsledky poskytuje filtrace pomocí vlnkové transformace nebo použití kumulace, kdy ale získáme jen reprezentativní vzorek signálu.
- *Impulzní rušení* - projevuje se rychlou skokovou změnou amplitudy signálu často až k maximální hodnotě. Bývá způsoben rušením od různých elektrických zařízení v blízkosti elektrokardiogramu. Tento typ rušení nelze jednoduše odstranit filtrem.
- *Další typy artefaktů* - na EKG záznamu se také objevují skokové změny izoelektrické linie, které jsou obvykle způsobeny špatným kontaktem elektrody s kůží. Dále se může v signálu vyskytnout šum elektronických součástí přístroje jako je šum použitých zesilovačů atd., stejně jako projevy dalších biologických artefaktů vznikajících při činnosti těla.

### 3. Projevy ischemie v EKG signálu

Ischemie srdce nastává, když je z nějakého důvodu omezeno prokrvení myokardu (např. uzavřením koronární tepny trombem). Ischemii způsobuje především nedostatek kyslíku (hypoxie) následně pak nedostatek živin, což vede k nahromadění škodlivých látek (odpadních produktů).

Ischemie se v srdečním rytmu projevuje charakteristickými změnami, které se ale obvykle nevyskytují ve všech ischemických srdečních cyklech. V EKG křivce jsou patrné zejména projevy akutní ischemie (angina pectoris). Změny EKG signálu můžeme rozdělit do dvou hlavních skupin, a to na změny morfologické a nemorfologické.

#### 3.1. Morfologické změny

Morfologické změny EKG signálu jsou velmi rozšířené při hodnocení EKG záznamu v klinické praxi, avšak pro automatické hodnocení srdečního rytmu jsou méně vhodné, protože automatické určení těchto parametrů je obtížné a citlivé na šum a rušení signálu.

Při ischemii dochází zejména ke změnám v ST segment a T vlně. K výrazným změnám v QRS komplexu dochází při transmurálním infarktu, avšak ischemie může způsobovat blokování Tawarových ramének, což vede prodloužení doby QRS komplexu. Změny v ST segmentu a T vlně nejsou specifické jen pro ischemii, objevují se také při hypertrofii levé komory nebo hypokalemii. [7],[8]


##### 3.1.1. T vlna

Ischemie ovlivňuje T vlnu různými způsoby: T vlna může být zvýšená, zploštělá, invertovaná nebo i bifázická. Vysoké hrotnaté T vlny viditelné v hrudních svodech jsou jedním z prvních příznaků akutního infarktu myokardu. Vysoké T vlny ve svodech V1 až V3 bývají důledkem ischemie zadní stěny levé komory. Změny T vlny způsobené ischemií jsou znázorněny na obrázku 7. [7],[8]

*Doporučovaná kritéria pro normální T vlnu:*

- velikost 1/8 až 2/3 R vlny
- výška max. 10 mm (1 mV)
- inverze T vlny může být normální nález ve svodech III, aVR a V1






Obr. 7: Změny T vlny v důsledku ischemie [7]

### 3.1.2. ST segment

Nejnápadnější změny v ST segmentu při ischemii představuje horizontální deprese (viz. Obr. 8) tohoto úseku. Jiné typy deprese ST segmentu se mohou projevit při hypertrofii levé srdeční komory. Deprese ST úseku se nejvíce viditelná ve svodech V4 – V6.

Dočasná elevace ST úseku je patrná při vazospastické angině pectoris. Spolu s elevací ST úseku se často vyskytuje také inverze T vlny. [7],[8]



Obr. 8: Deprese ST segmentu (svod V2) [6]

### 3.1.3. Arytmie spojené s akutní srdeční ischemií

Komorová ischemie může být arytmogenní faktor, který vede k výskytu extrasystol. Komorová fibrilace je nejčastějším typem fatální arytmie, která nastává do 24h po akutním infarktu myokardu. [7]

## 3.2. Nemorfologické změny

Nemorfologické změny v EKG signálu bývají vhodnější pro automatickou detekci ischemie, protože pro jejich určení není nutné provádět rozměrování EKG signálu, které je obtížné. Nemorfologické parametry EKG signálu jsou také zpravidla méně náročné na kvalitu


použitého signálu. Avšak morfologické parametry mohou být pro detekci ischemie citlivější a jejich použití se nabízí, pokud jsou k dispozici již rozměřené EKG signály.

Existuje velké množství nemorfologických parametrů, které je možné z EKG signálu určit. Je možné zpracovávat signál časově-frekvenční oblasti pomocí vlnkové transformace (WT). Nebo využít analýzu hlavních komponent, což je původně statistická metoda sloužící zejména k snížení dimenze dat. Zajímavé informace poskytuje také analýza srdečního rytmu, která vychází z hodnocení variability intervalů mezi R vlnami. Jinou možností je zpracovávat signál ve frekvenční oblasti, v tomto případě se obvykle provádí odhad výkonového spektra signálu. Výstupem všech těchto metod je vytvoření vektoru příznaků pro následnou klasifikaci ischemických a neischemických průběhů EKG.

## 4. Automatická detekce ischemie

Automatická detekce ischemie z EKG záznamů je komplikovaný proces, který lze zjednodušeně popsat v několika krocích schematicky zobrazených na obrázku 9.

Prvním krokem je získání vhodných záznamů EKG a to buď měřením na pacientovi, použitím signálu z různých databází nebo z experimentálního měření. Následuje předzpracování zvolených signálů, kdy se snažíme vhodnými postupy potlačit rušení a artefakty vyskytující se v těchto signálech a vybrat úseky EKG relevantní pro analýzu ischemie (viz. kapitola 3). Dalším krokem je vytvoření vektoru příznaků pro jejich klasifikaci zvolenou detekční metodou. Vektor příznaků je obvykle ještě nutné upravit, protože získaný vektor příznaků je dlouhý a ne všechny příznaky jsou pro klasifikaci signálu užitečné. Posledním ale velmi důležitým krokem je vlastní klasifikace EKG záznamu do 2 nebo více tříd pomocí vybraného klasifikátoru. Pro praktické využití automatického detektoru ischemie je také potřeba provést zhodnocení účinnosti klasifikace (pomocí senzitivity, specifity a dalších indikátorů úspěšnosti). [9]



Obr. 9: Obecné schéma automatické detekce ischemie

### 4.1. Získání a předzpracování dat

V klinické praxi jsou obvykle zdrojem dat měření prováděná přímo na pacientovi. Data můžeme také získat z různých databází EKG signálů jako je např. MIT-BIH [10] a další. Tyto databáze jsou velmi užitečné pro ověření funkce navrženého detektoru. Dalším zdrojem dat jsou experimentální měření. V tomto případě se obvykle jedná o data získaná z invazivního měření na zvířatech. Výhodou takto získaných dat je to, že jsou získány za definovaných podmínek. Nevýhodou je, že projevy ischemie v EKG záznamech zvířecích srdcí se mohou od těch lidských mírně lišit.

Úkolem předzpracování dat upravit analyzovaný EKG signál tak, aby se potlačily artefakty a rušení, které negativně ovlivňují výsledky použité detekční metody pro vytvoření vektoru příznaků. [9]

Typicky jsou při předzpracování dat používány postupy, jako je:

- odstranění kolísání nulové linie
- potlačení síťového rušení
- potlačení myopotenciálů, atd.

## 4.2. Vytvoření vektoru klasifikačních příznaků

Vytvoření vektoru klasifikačních příznaků představuje úpravu původního EKG signálu do podoby vhodné pro jeho následnou klasifikaci. Snažíme se dosáhnout toho, aby vektor příznaků obsahoval všechny relevantní informace z původního signálu a došlo k potlačení šumu a nedůležitých složek ze signálu, které by ovlivnily klasifikaci. Dále jsou stručně popsány některé metody pro vytvoření vektoru příznaků.

Jako vektor příznaků je také možné vzít přímo vzorky EKG signálu. Není to ovšem příliš vhodné, protože EKG signál ale dlouhý (stovky vzorků na jeden R-R interval), klasifikace je pak výpočetně náročnější. Počet vzorků signálu je možné snížit např. decimací, ale může dojít k potlačení důležitých složek signálu.

### 4.2.1. Morfologické parametry

Jak již bylo zmíněno v kapitole 3.3, morfologické parametry EKG signálu jsou v klinické praxi pro hodnocení ischemie srdce používány nejčastěji. Jako vektor příznaků jsou tedy použity hodnoty morfologických parametrů přímo odečtených z EKG signálu.

V tabulce 1 jsou uvedeny typické hodnoty nejčastěji hodnocených morfologických parametrů EKG. [9]

Tabulka 1: Normální hodnoty morfologických parametrů sinusového rytmu při tepové frekvenci 60 tepů/s u zdravého muže (svod II) [9]

Parametr	Normální hodnota	Normální meze
Šířka P vlny	110 ms	$\pm 20$ ms
PQ interval	160 ms	$\pm 40$ ms
Šířka QRS	100 ms	$\pm 20$ ms
QT interval	400 ms	$\pm 40$ ms
Amplituda P vlny	0,15 mV	$\pm 0,05$ mV
Amplituda QRS komplexu	1,5 mV	$\pm 0,5$ mV
Amplituda ST úseku	0 mV	$\pm 0,1$ mV
Amplituda T vlny	0,30 mV	$\pm 0,2$ mV


Při experimentálních měřeních se využívají i další nestandardní morfologické parametry, jako je např. parametr ST60, který udává amplitudu ST úseku ve vzdálenosti 60 ms od bodu J. [19]

V důsledku ischemie nebo z důvodů vzniku arytmií dochází k charakteristickým změnám hodnot těchto parametrů (viz kapitola 3.3), což umožňuje využít tyto parametry pro detekci patologických srdečních rytmů.

#### 4.2.2. Frekvenční analýza

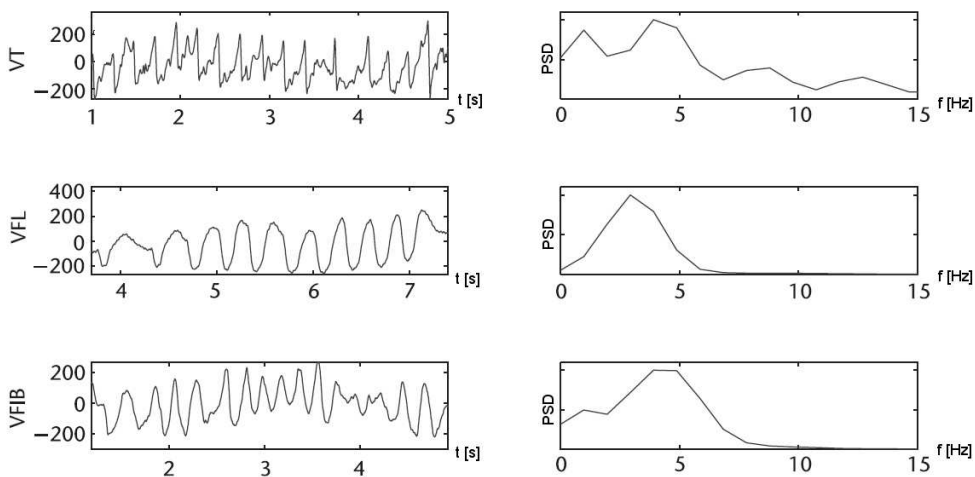
Nejčastěji analyzovaným spektrálním parametrem EKG signálu je výkonové spektrum (PSD – Power spectral density). Výkon EKG signálu na různých frekvencích souvisí zejména s projevy P vlny, T vlny a QRS komplexu, které se projevují typickými píky na frekvencích asi 1 Hz, 4 Hz, 7 Hz a 10 Hz. Rozložení spektrálního výkonu bývá ve všech svodech velmi podobné. [9]

Na obrázku 10 je typické výkonové spektrum normálního sinusového EKG signálu.



Obr. 10: Výkonové spektrum normálního EKG signálu [9]

Projevy fyziologických změn srdečního rytmu ve výkonovém spektru jsou minimální. Významné změny ve výkonovém spektru nastávají až při výrazných změnách v EKG signálu např. při arytmiích, ischemii atd. Vlivy některých arytmií (VT – komorová tachykardie, VFL – flutter komor, VFIB – komorová fibrilace) na výkonové spektrum EKG jsou na obrázku 11.



Obr. 11: Projevy arytmií ve výkonovém spektru (PSD) EKG [9]

Vektorem příznaků je v tomto případě výkon EKG signálu na různých frekvencích. Tento vektor může být dále upravován, nebo lze hodnotit jen některé části spektra atd. Analýza výkonového spektra není pro detekci ischemie běžně používána.

### 4.2.3. Časově-frekvenční analýza

Vlnková transformace je metoda často používaná pro zpracování, rozměrování a filtraci EKG signálu. Jedná se o metodu, která má za cíl vytvořit časově – frekvenční popis signálu. Vlnková transformace se dělí na spojitou a diskretní.

Vlnková transformace využívá jako báze funkce tzv. mateřské vlnky popsané následujícím vztahem: [18]

$$d\psi_{\lambda,\vartheta}(t) = \frac{1}{\sqrt{\lambda}} \psi\left(\frac{t-\vartheta}{\lambda}\right), \quad (1)$$

Spojitou vlnkovou transformaci (CWT – Continuous wavelet transform) je možné chápat jako korelaci signálu  $x(t)$  se spojitým časem s báze funkcí (vlnkou) dle následujícího vztahu: [18]


$$y(\lambda, \vartheta) = \frac{1}{\sqrt{\lambda}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-\vartheta}{\lambda}\right) dt, \quad (2)$$

kde  $\lambda$  je měřítko (časová dilatace) mateřské vlnky a  $\vartheta$  je parametr, který popisuje časové posunutí vlnky.

Dyadická vlnková transformace s diskretním časem (DTWT – Discrete time wavelet transform) diskretního signálu  $x(n)$  je definována obdobně jako diskretní konvoluce podle následujícího vztahu: [18]

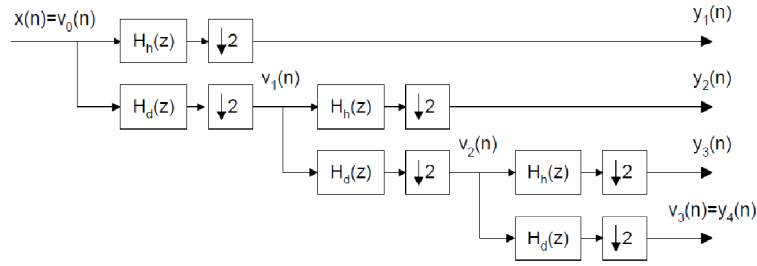
$$y_m(n) = \sum_{i=-\infty}^{\infty} x(i) h_m(2^m n - i) = \sum_{i=-\infty}^{\infty} h_m(i) x(2^m n - i), \quad (3)$$

Dyadická DTWT  $y_m(n)$  se realizuje rozkladem signálu  $x(n)$  bankou diskretních oktavových filtrů s impulzními charakteristikami  $h_m(n)$ . Schéma dyadické DTWT je na obrázku 12.



Obr. 12: Realizace třístupňové dyadické DTWT bankou oktavových filtrů s podvzorkováním[18]

Často je využívána tzv. rychlá DTWT, jejíž schéma je na obrázku 13. V tomto případě se použije dvojice zrcadlových filtrů  $H_h(z)$  a  $H_d(z)$  a podvzorkování s faktorem 2. [18]



Obr. 13: Schéma třístupňové rychlé DTWT [18]

Vektorem příznaků jsou pak příslušné koeficienty vlnkové transformace, které mohou být dále zpracovávány a použity pro klasifikaci. Vlnková transformace se také používá pro např. kompresi dat, k analýze proudění tekutin, v astronomii atd.

#### 4.2.4. Analýza variability srdečního rytmu

Variabilita srdečního rytmu (HRV – heart rate variability) je označení pro oscilaci intervalů srdečních cyklů. Srdeční rytmu fyziologicky řízený z SA uzlu je dále ovlivňován sympatickým (zvýšení frekvence) a parasympatickým (snížení frekvence) autonomním nervovým systémem. Aktivita autonomního nervového systému tedy vede k variabilitě srdečního rytmu. [16][17]

HRV se určuje z intervalů mezi R kmity (R-R interval) označované často jako NN (normal – normal). Analýza variability srdečního rytmu se může provádět v časové nebo frekvenční oblasti. [16][17]

V časové oblasti se přímo vychází ze zjištěných hodnot R-R intervalů. Používají se různé statistické parametry, jako je směrodatná odchylka R-R intervalů (SDNN):

$$SDNN = \sqrt{\frac{1}{N-1} \sum_{j=1}^N (RR_j - \overline{RR})^2} \quad , \quad (4)$$

kde  $N$  je celkový počet R-R intervalů,  $RR_j$  je hodnota  $j$ -tého R-R intervalu a  $\overline{RR}$  je průměrná hodnota všech R-R intervalů.

Dalším parametrem je směrodatná odchylka rozdílů mezi sousedními R-R intervaly (SDSD):

$$SDSD = \sqrt{E\{\Delta RR_j^2\} - E\{\Delta RR_j\}^2} \quad , \quad (5)$$

RMSSD je odmocnina průměrů druhých mocnin po sobě jdoucích R-R intervalů, vypočtená podle následujícího vztahu:

$$RMSSD = \sqrt{\frac{1}{N-1} \sum_{j=1}^{N-1} (RR_{j+1} - RR_j)^2}, \quad (6)$$

Další často používaný parametr je pNN50, tedy procento R-R intervalů lišících se o více než 50 ms:

$$pNN50 = \frac{NN50}{N-1} \cdot 100 [\%], \quad (7)$$

V časové oblasti lze také využívat geometrické metody, které vycházejí např. z histogramu R-R intervalů, jako je trojúhelníkový index nebo hodnocení šířky histogramu pomocí parametru *TINN*.

Jinou možností hodnocení HRV je analýza ve frekvenční oblasti. V tomto případě se určuje výkonové spektrum ze série R-R intervalů. A hodnotí se výkon v předem definovaných frekvenčních pásmech:

ULF – ultra nízké frekvence ( < 0,003 Hz)

VLF – velmi nízké frekvence ( 0,003 – 0,04 Hz)

LF – nízké frekvence ( 0,04 – 0,15 Hz)

HF – vysoké frekvence ( 0,15 – 0,4 Hz)

Dále ještě existují nelineární metody analýzy HRV, jako jsou Poincarého grafy nebo metoda aproximativní entropie aj. [16][17]

#### 4.2.5. Analýza hlavních komponent

Analýza hlavních komponent (PCA – Principal Component Analysis) je původně statistická metoda, jejímž úkolem je transformovat původní korelované proměnné na nové proměnné, které spolu nekorelují. Z původního velkého množství proměnných pak lze vybrat jen několik proměnných, které přesto obsahují většinu informací z původních proměnných. [12]

Prvním krokem analýzy hlavních komponent je vytvoření matice kovariancí nebo korelací analyzovaných dat. Kovarianční matice je vhodná pro data, která mají stejný význam, stejné jednotky apod. Kovarianční matice se počítá podle následujícího vztahu [12]:

$$cov_{xy} = \sum_{k=0}^{N-1} [x(k) - \mu_x][y(k) - \mu_y], \quad (8)$$

kde  $x(k)$  je k-tý vzorek proměnné  $x$ ,  $y(k)$  je k-tý vzorek proměnné  $y$ ,  $\mu_x$  a  $\mu_y$  jsou střední hodnoty proměnných  $x$  a  $y$ .

Kovarianční matice je čtvercová matice, která má na hlavní diagonále rozptyl mezi proměnnými, ostatní prvky obsahují hodnoty kovariance mezi proměnnými. Kovarianční matice je tedy symetrická podle hlavní diagonály.



Pokud jsou jednotky proměnných různé, je vhodnější použít korelační matici, která se počítá podle vztahu [12]:

$$cor_{xy} = \frac{cov_{xy}}{\sqrt{\sigma_x^2 + \sigma_y^2}}, \quad (9)$$

kde  $\sigma_x^2$  je rozptyl proměnné  $x$  a  $\sigma_y^2$  je rozptyl proměnné  $y$ . Na hlavní diagonále je u korelační matice hodnota 1, které vyjadřuje, že každá proměnná maximálně koreluje sama se sebou. V ostatních prvních matice jsou hodnoty korelace pro různé dvojice proměnných. Matice je opět čtvercová a symetrická podle hlavní diagonály. Korelace je vlastně kovariance na standardizovaných datech.

Dalším krokem PCA je výpočet tzv. vlastních čísel (eigenvalues). Výpočet je popsán následujícím vztahem [12]:

$$|A - \lambda_i I| = 0, \quad (10)$$

Kde  $A$  je již dříve zmíněná kovarianční nebo korelační matice a  $\lambda_i$  je  $i$ -té vlastní číslo.  $I$  je jednotková matice. Pomocí těchto vlastních čísel se určí, vyčerpaná variabilita vypočítané komponenty.

Následuje výpočet vlastních vektorů podle vztahu[12]:

$$(A - \lambda_i I) * u_i = 0, \quad (11)$$

kde  $A$  je opět korelační nebo kovarianční matice,  $\lambda_i$  jsou vlastní čísla a  $u_i$  je  $i$ -tý vlastní vektor. Vlastní vektory se následně sestaví do matice, tak že vektory tvoří sloupce této matice. Takto vytvořená matice se označuje jako matice koeficientů. Výstupní hlavní komponenty se pak počítají podle vztahu[12]:

$$y_1 = \sum_{j=1}^m v_{1j} x_j = v_1^T x, \quad (12)$$

kde  $y_1$  je první hlavní komponenta,  $x$  jsou vstupní proměnné a  $v_1^T$  je vektor koeficientů.

První hlavní komponenta vyjadřuje největší část rozptylu ze vstupních dat. Druhá hlavní komponenta vyjadřuje největší část rozptylu, která není obsažena první hlavní komponentou atd. Každá hlavní komponenta tak vyčerpává nějakou část variability dat. Obvykle je nutno vybrat tolik hlavních komponent, aby bylo vyčerpáno 80% - 90% variability. Zbývající komponenty už obvykle obsahují především šum.

Analýza hlavních komponent může být použita k získání vektoru příznaků a to, buď z celého P-QRS-T úseku EKG signálu nebo jen z některých vybraných segmentů. PCA může být také použita pro redukci počtu příznaků získaných jinou metodou. V praxi je analýza hlavních komponent využívána i pro kompresi signálů nebo rozeznávání obličejů. Analýza hlavních komponent byla v této práci použita pro snížení počtu příznaků v klasifikačním vektoru.

### 4.3. Klasifikace

Klasifikací EKG signálu je myšleno zařazení zkoumaného signálu do jedné ze dvou nebo více předem známých kategorií, např. ischemický vs. normální. Existuje větší množství klasifikátorů použitelných pro klasifikaci ischemie v EKG. V této kapitole jsou některé z nich stručně popsány. Umělé neuronové sítě jsou zde popsány detailněji, protože byly zvoleny jako klasifikátor v praktické části práce.

#### 4.3.1. Lineární diskriminační analýza

Lineární diskriminační analýza (LDA) je metoda, která využívá proměnných (prediktorů), které diskriminují mezi předem známými skupinami objektů. Cílem je klasifikace objektů do skupin. LDA používá soustavu lineárních rovnic, které tvoří oddělovací přímky (nadroviny). Vzdálenost objektů od oddělovací přímky určuje spolehlivost klasifikace. Lineární diskriminační analýza využívá stejně jako neuronové sítě trénovací množinu dat. LDA našla uplatnění např. v biologii, medicíně nebo bankovníctví. [12]

#### 4.3.2. Shluková analýza


Shluková analýza je označení pro skupinu metod, jejichž úkolem je klasifikovat objekty do tříd na základě podobnosti objektů. Objekty patřící do jedné skupiny by si měly být co nejvíce podobné, zatímco objekty patřící do jiné skupiny by se měly co nejvíce lišit. Používá se více kritérií podobnosti mezi objekty, obvykle vycházejí ze vzdálenosti objektů ve vícerozměrném prostoru. [12]

Existuje více typů shlukové analýzy, základní dělení je na metody *hierarchické* a *nehierarchické*. U hierarchických metod jsou shluky definovány postupným slučováním objektů. Tyto metody se dále dělí na *divizní*, kdy jsou objekty rozděleny na dva shluky a tyto shluky se v dalších krocích znovu dělí a na metody *aglomerativní*, kdy se nejdříve spojují nejpodobnější objekty a v dalších krocích dochází k přidávání dalších objektů do shluků. Výstupem hierarchických metod je dendrogram, kde existuje více alternativních možností rozdělení objektů do shluků. U nehierarchických divizních metod je počet shluků dopředu určen. [12][15]

#### 4.3.3. Umělé neuronové sítě

Umělé neuronové sítě (ANN – artificial neural network) jsou prostředkem pro paralelní zpracování a klasifikaci dat. Původně byly vytvořeny pro modelování základních procesů probíhajících v mozku, jako jsou paměť nebo učení.

Základní jednotkou umělých neuronových sítí je umělý neuron. Příkladem může být jednoduchý perceptron, který má  $n$  vstupů ( $x_1 \dots x_n$ ) a  $n$  příslušných vah ( $w_1 \dots w_n$ ) a jeden výstup  $y$  (viz Obr. 14).




Obr. 14: Jednoduchý perceptron

Výstup  $y$  je váženým součtem vstupních hodnot podle následujícího vztahu:

$$y = f\left(\sum_{i=1}^k x_i * w_i - \theta\right), \quad (13)$$

kde  $f$  je aktivační funkce neuronu,  $x_i$  je  $i$ -tý vstup,  $w_i$  je příslušná váha,  $\theta$  je práh neuronu a  $y$  je výstup neuronu.


Nejjednodušším příkladem využití neuronu pro klasifikaci je neuron se dvěma vstupy a jedním binárním výstupem. V tomto případě neuron klasifikuje vstupy do dvou tříd a to na základě toho, zda jsou hodnoty vstupů nad nebo pod dělicí přímkou. Parametry dělicí přímky jsou dány nastavením vah a aktivační funkce neuronu. Aktivační funkce neuronu může být skoková, lineární nebo sigmoidní atd. Ukázky průběhu těchto funkcí jsou na obrázku 15.



Obr. 15: Aktivační funkce umělého neuronu: skoková(a), po částech lineární(b) a sigmoidní(c)

## Využití perceptronu pro klasifikaci

Při využití perceptronu (neuronu) pro klasifikaci může uvažovat nejjednodušší případ, kdy neuron má dva vstupy a binární výstup (skoková aktivační funkce). Vstupní hodnoty budou tedy klasifikovány do dvou tříd. Tento neuron má tedy vstupy  $x_1$  a  $x_2$  a příslušné váhy  $w_1$  a  $w_2$  a binární výstup  $y \in \{0,1\}$ . Takový neuron pak klasifikuje dvojici hodnot  $x_1$  a  $x_2$  do dvou tříd A a B. Sklon dělicí přímky je dán hodnotami vah a pozice přímky hodnotou prahu. Schématické znázornění je na obrázku č. 16.



Obr. 16: Klasifikace do dvou tříd (A, B) jedním perceptronem [23]

Spojováním více perceptronů vznikají neuronové sítě. Neuronové sítě využívají proces učení, kdy síť v průběhu učení mění nastavení vah, tak aby došlo k minimalizaci chyby na výstupu. Různým propojením perceptronů vznikají odlišné topologie neuronových sítí jako jsou dopředné neuronové sítě (feed forward), které využívají učení s učitelem. Jiným typem jsou rekurentní sítě jako jsou Hopfieldovy nebo Kohonenovy sítě, které využívají tzv. učení bez učitele. [13][14]


### Dopředné neuronové sítě (feed forward)

Nejběžnějším typem dopředné neuronové sítě je vícevrstvá neuronová síť, jejíž schématické zobrazení je na obrázku č. 17. Jako dopředné jsou tyto sítě označovány proto, že výstupy z perceptronů jsou předávány jen v dopředném směru mezi vrstvami, neexistuje zde tedy žádná zpětná vazba.

Tyto sítě se obecně skládají z 3 nebo více vrstev: vstupní vrstvy, skryté vrstvy a výstupní vrstvy. Počet neuronů ve vstupní vrstvě je vždy stejný, jako je délka příznakového vektoru, vstupní vrstva slouží k distribuci hodnot na vstupy skryté vrstvy a výstup z každého neuronu ve vstupní vrstvě je přiveden na vstup každého neuronu ve skryté vrstvě. Počet neuronů ve

skryté vrstvě se obvykle stanovuje empiricky, přičemž skrytých vrstev může být víc. Výstupy z neuronů ve skryté vrstvě opět vedou na vstup neuronů ve výstupní vrstvě. Počet neuronů ve výstupní vrstvě je dán počtem požadovaných klasifikačních tříd. Pro klasifikaci dat do 2 tříd stačí 1 výstupní neuron (1 bit). Dva neurony ve výstupní vrstvě umožňují klasifikaci do 4 tříd (2 bity) atd. Pro klasifikaci do více tříd lze také využít jeden neuron s lineární aktivační funkcí.

U neuronů ve skryté vrstvě se obvykle využívá nelineární sigmoidní aktivační funkce, která součet vstupů transformuje do intervalu  $<0,1>$  a to tak, že v blízkosti nuly funkce prudce roste a u vysokých a nízkých hodnot se mění jen málo. Ve výstupní vrstvě se využívá skoková nebo lineární aktivační funkce. [13],[14],[23]



Obr. 17: Dopředná neuronová síť s jednou skrytou vrstvou

### Učení dopředné neuronové sítě

Dopředné neuronové sítě využívají pro učení algoritmus zpětného šíření chyby (backpropagation). V tomto případě jsou na vstupu neuronové sítě vektory klasifikačních příznaků, u kterých je známo, do které třídy příslušné vektory patří. Tyto vektory tvoří tzv. trénovací množinu. Jedná o tzv. učení s učitelem.

Učení tohoto typu sítě probíhá v následujících krocích: [23]

1. síti je předložen vektor vstupních dat, na tato data zareagují všechny neurony a získá se výstup (odezva) sítě,
2. následuje výpočet chyby sítě  $E$ , jedná se o střední kvadratickou odchylku (MSE - mean squared error) podle vztahu:

$$E = \frac{1}{n} \sum_{j=1}^n (y_j - t_j)^2, \quad (14)$$

kde  $y_j$  je výstup (odezva) sítě na  $j$ -tý vzor,  $t_j$  je očekávaný výstup sítě.


3. nakonec dojde k úpravě vah každého neuronu podle vztahu:

$$w_i = -\eta \frac{\delta E}{\delta w_{i-1}} + w_{i-1}, \quad (15)$$

kde  $\eta$  je koeficient učení a  $w_{i-1}$  představuje hodnoty vah v předchozím kroku učení.

Smyslem učení je minimalizace hodnoty chybové funkce (14). Výše uvedený vztah (15) představuje tzv. metodu gradientního sestupu, kdy principem metody je posun z předchozí pozice do pozice současné ve směru záporného gradientu chybové funkce.

Při učení neuronové sítě může dojít k situaci, kdy hodnota chybové funkce sítě na trénovacích datech klesá, ale hodnota chyby na testovacích datech naopak stoupá (Obr. 17). Tato situace se označuje jako přeučení sítě (overfitting). K tomuto jevu může docházet např. pokud je k dispozici malý počet dat (pozorování) a zároveň je klasifikační vektor dlouhý. K omezení tohoto jevu je možné použít funkci předčasného ukončení učení (early stopping), kdy jsou dostupná data rozdělena do 3 množin: trénovací, validační a testovací. Trénovací množina je použita pro učení sítě, tedy optimalizaci nastavení prahů a vah sítě. Dále je sledována chyba sítě po předložení validační množiny dat. Z počátku hodnota chybové funkce pro trénovací i validační množinu klesá. Po dosažení určitého počtu iterací (epoch učení) začne hodnota chybové funkce sítě na validačních datech růst a v tomto okamžiku je učení sítě ukončeno. Třetí tzv. testovací množina dat není v průběhu učení sítě vůbec použita a slouží ke zjištění chyby naučené sítě. [13],[14],[23]



Obr. 18: Průběh chyby sítě v závislosti na počtu epoch učení

Dalším vlivem na hodnoty chybové funkce a tedy i výsledky klasifikace je to, že výchozí nastavení vah a prahů perceptronů v síti se volí náhodně. Důsledkem je, že výsledky klasifikace při opakovaném učení sítě na stejných datech jsou odlišné. Tento vliv je opět možné omezit např. opakovaným učením sítě na stejných datech a zprůměrováním výsledků. [23]

#### 4.4. Křížová validace


Křížová validace je metoda, která umožňuje opakované testování klasifikátoru na nezávislých vzorcích dat. Principem křížové validace je rozdělení vstupní sady dat na podmnožiny. Vždy je jedna podmnožina použita na testování klasifikátoru a zbývající podmnožiny na jeho učení.

Nejpoužívanějším typem křížové validace je K-fold křížová validace. V tomto případě jsou data rozdělena na  $k$  množin. Nejčastěji se volí rozdělení dat na 10 podmnožin (10-fold

validation). V prvním kroku je pro testování použita 1. podmnožina a zbývající podmnožiny (2. až 10.) jsou použity pro učení sítě. V dalším kroku je pro testování použita 2. podmnožina a zbývající (1. a 3. až 10.) jsou použity pro učení sítě atd.

Klasifikace tak probíhá opakovaně na různých učebních a testovacích množinách vytvořených z dostupných dat.

Schéma K-fold křížové validace je na obr. 19.



Obr. 19: K-fold křížová validace

Jinou možností je opakovaně náhodně vybírat data do učební a testovací množiny ve zvoleném poměru (repeated random sub-sampling cross validation)[23]. Tato metoda byla použita v praktické části práce. Výhodou tohoto přístupu je, že na rozdíl o křížové validace velikost testovací a učební množiny nezávisí na počtu opakování výběru. U K-fold křížové validace je při rozdělení dat do 10 podmnožin použito vždy 90 % dat pro učení sítě a 10 % dat pro testování sítě, při rozdělení dat do 100 podmnožin je pak pro učení sítě použito 99 % dat a pro testování sítě už jen 1 %. Pokud jsou data do učební množiny vybírány náhodně, může být tento poměr libovolný. Takto získané výsledky je možné zprůměrovat a tím dostat přesnější, více vypovídající výsledek. Nevýhodou této metody je to, že některé vzorky nikdy nemusí být vybrány do testovací množiny a naopak některé vzorky mohou být vybrány opakovaně. [23]

#### 4.5. Hodnocení klasifikační účinnosti

Pro hodnocení účinnosti klasifikace existuje celá řada parametrů. Nejčastěji se uvádí *senzitivita* (16) a *specifická* (17). Senzitivita vyjadřuje poměr počtu skutečně pozitivních (TP) případů k počtu skutečně pozitivních a falešně negativních (FN). Tedy poměr správně detekovaných pozitivních případů ku všem pozitivním případům. Naopak specifická je poměr počtu skutečně negativních (TN) k počtu falešně pozitivních (FP) a skutečně negativních. Vyjadřuje tedy poměr správně detekovaných negativních případů k všem negativním případům.

$$\text{Senzitivita} = \frac{TP}{TP+FN} [\%], \quad (16)$$

$$Specificita = \frac{TN}{FP+TN} [\%], \quad (17)$$

Dále jsou také často používané parametry *celková úspěšnost* a *pozitivní prediktivní hodnota*. Úspěšnost je definována jako poměr skutečně negativních a skutečně pozitivních ku všem případům. Vyjadřuje tak poměr správně detekovaných případů (pozitivních i negativních) k všem případům. Pozitivní prediktivní hodnota je pak poměr skutečně pozitivních k součtu skutečně pozitivních a falešně pozitivních.

$$Celková\ úspěšnost = \frac{TP+TN}{TP+FN+FP+TN}, \quad (18)$$

Pozitivní prediktivní hodnota:

$$+P = \frac{TP}{TP+FP}, \quad (19)$$

#### 4.6. Přehled nejčastěji používaných klasifikačních metod

Tabulka 2 (viz. níže) obsahuje přehled metod použitelných pro automatickou detekci ischemie a arytmií. Úspěšnost použitých metody je zde popsána pomocí senzitivity (Se) a pozitivní prediktivní hodnoty (+P).

Tabulka 2: Přehled metod použitelných pro detekci ischemie a arytmií (převzato z [11])

Autoři (rok)	Metoda	Se (%)	+P (%)
P. de Chazal, M. O'dwyer, R.B. Reily (2004)	Morfologické příznaky a LDA	78,9	76,0
J. Garcia., L. Sornmo (2006)	RMS metoda	85	86
F. Jager, G. B. Moody (1998)	PCA	87	88
P. Ranjith, P.C. Baby, P. Joseph (2003)	Vlnková transformace	92	86
M. J. Polak, S. H. Zhout (1995)	Adaptivní logická síť	72	66
N. Maglaveras, T. Stamkopolos, C. Papaas, M. G. Strinzis (1998)	Síť se zpětným šířením chyby	89	78,4
M. J. Polak, S. H. Zhout (1995)	Adaptivní síť	88.62	100
M. J. Polak, S. H. Zhout (1995)	Diskriminantová metoda	62	66
J. Vila, J. Presedo (1997)	Fuzzy logika	83	75



R. V. Andreao, B. Dorizzi (2004)	HMM	89	85
T. Goletsis, C. Papaloukas, D. I. Fotiadis, L. K. Michalis (2004)	Genetické algoritmy	91	91
D. Papaloukas, D. J. Fotiadis (2002)	Parametrické modelování	81	84
T. Stamkopolous, N. Maglaveras (1998)	PCA a ANN	90	93
C. Papaloukas, D. I. Fotiadis (2001)	Soubor pravidel	70	63
T. P. Exarchos, C. Papaloukas (2006)	Rule mining	87	93
S. Papadimitriou, S. Mavroudi, L. Vliadutu, A. Bezerianos (2001)	SOM	74,9	73,7
S. Papadimitriou, S. Mavroudi, L. Vliadutu, A. Bezerianos (2001)	SOM a RBF	79,5	77,6
S. Papadimitriou, S. Mavroudi, L. Vliadutu, A. Bezerianos (2001)	SOM a SVM	82,8	82,4
T. Goletsis, C. Papaloukas, D. I. Fotiadis, Aristidis and L. K. Michalis (2001)	HySMID	91	93
L. Dranca, A. Goni (2006)	Rozhodovací stromy	89,9	70,0
R. Silipo, C. Marchesi (1998)	Rekurentní ANN	77	85
R. Silipo, C. Marchesi (1998)	Znalosti se učící ANN	71	66

LDA – lineární diskriminační analýza

PCA – analýza hlavních komponent

HMM – skryté Markovovy modely

ANN – umělá neuronová síť

SOM – samoorganizující se mapy

SVM – support vector machine

Jak je z tabulky patrné, žádná z metod není 100% úspěšná, některé však dosahují senzitivity a pozitivní prediktivní hodnoty nad 90%. Účinnost klasifikace je také ovlivněna počtem klasifikačních tříd – klasifikace do více než 2 tříd je náročnější.

## 5. Automatická detekce ischemie v experimentálních datech

V této kapitole je popsána metoda výpočtu morfologických parametrů z EKG signálu, které slouží jako vektor příznaků pro pozdější automatickou detekci ischemických průběhů.

Je zde také uveden popis použitých experimentálních dat a statistické zhodnocení vypočtených morfologických parametrů a dále popsán postup vlastní klasifikace srdečních cyklů zvoleným klasifikátorem.


### 5.1. Popis experimentálních dat

Data použitá v této práci byla získána měřením EKG signálu na izolovaných srdcích novozélandských bílých králíků. Experiment byl proveden na Fyziologickém ústavu lékařské fakulty Masarykovy univerzity v Brně ve spolupráci s Ústavem biomedicínského inženýrství VUT v Brně.

Při experimentu byla zvířata uvedena do anestezie a následně jim byla chirurgicky vyjmuta srdce. Extrahované srdce bylo poté vloženo do měřicí aparatury a promýváno Krebs-Henseleitovým roztokem (Langendorffův perfúzní systém) o teplotě 37°C a konstantním tlaku 85 mmHg.


V první fázi experimentu byla srdce promývána Krebs-Henseleitovým roztokem po dobu 15 min pro stabilizaci. Tato fáze je označena jako kontrolní fáze, bez vlivu ischemie. Po uplynutí této doby byl průtok roztoku měřicím systémem ukončen na dobu 15 min, čímž byla u králičích srdcí vyvolána globální ischemie. Následně byl průtok roztoku systémem obnoven a ukončen ještě třikrát.

V průběhu celého experimentu byla snímána elektrická aktivita srdce pomocí ortogonálně umístěných elektrod na stěnách nádoby (viz Obr. 19), kde bylo srdce při experimentu umístěno. [20][21][22]




Obr. 20: Langendorffův perfúzní systém a schéma umístění měřicích elektrod [22]

Na následujících obrázcích jsou EKG průběhy získané z měření na izolovaných srdcích novozélandských králíků. Jedná se o data snímaná ze 6 různých králíků, celkem 4985 srdečních cyklů pro kontrolní a ischemickou fázi experimentu. Všechny průběhy mají délku 500 vzorků. Úseky srdečního cyklu odpovídající oblasti P vlny byly odstraněny, protože tato část EKG průběhu není pro detekci ischemie důležitá.



Obr. 21: EKG průběhy – kontrola (svod X)



Obr. 22: EKG průběhy – ischemie (svod X)

Z uvedených průběhů EKG signálů je vidět poměrně velká variabilita mezi různými cykly a to i v kontrolní fázi. V ischemické fázi se variabilita průběhů zvyšuje a jsou vidět některé charakteristické projevy ischemie, jako deprese nebo elevace ST úseku, rozšíření QRS komplexu, změny v poloze a amplitudě T vlny. V některých průbězích je také vidět inverze T vlny. Mezi ischemickými průběhy existuje větší variabilita, to může být způsobeno mírně odlišnými reakcemi srdcí z různých králíků na ischemii.

EKG průběhy snímané pomocí ostatních svodů v kontrolní i ischemické fázi experimentu jsou v příloze č.1.

## 5.2. Vytvoření vektoru klasifikačních příznaků

Jako vektor příznaků pro klasifikaci srdečních cyklů byly použity morfologické parametry vypočtené z výše uvedených EKG průběhů v Matlabu.

U každého srdečního cyklu byly nejdříve ručně definovány 3 body: bod  $q$ , odpovídá začátku QRS komplexu, bod  $j$  odpovídá konci QRS komplexu a bod  $t$ , který odpovídá konci T vlny.


Pro každý cyklus byly vypočteny následující parametry:

- **$QJ$**  – časový úsek mezi bodem  $q$  a  $j$ , tedy vlastně délka trvání QRS komplexu [ms]
- **$QT$**  – časový úsek mezi bodem  $q$  a  $t$ , tedy čas od počátku QRS komplexu do konce T vlny [ms]
- **$JT$**  – časový úsek mezi bodem  $j$  a  $t$ , tedy čas od konce QRS komplexu do konce T vlny [ms]
- **$JTamp$**  – časový úsek od bodu  $j$  po vrchol T vlny [ms]
- **$Tamp$**  – amplituda T vlny [ $\mu V$ ]
- **$ST10$**  – amplituda ST úseku v bodě  $j + 10$  ms [ $\mu V$ ]
- **$ST20$**  – amplituda ST úseku v bodě  $j + 20$  ms [ $\mu V$ ]
- **$ST30$**  – amplituda ST úseku v bodě  $j + 30$  ms [ $\mu V$ ]
- **$ST40$**  – amplituda ST úseku v bodě  $j + 40$  ms [ $\mu V$ ]
- **$ST50$**  – amplituda ST úseku v bodě  $j + 50$  ms [ $\mu V$ ]
- **$AUCqrst$**  – plocha pod křivkou tvořenou od bodu  $q$  do bodu  $t$ , tedy plocha pod křivkou celého úseku od počátku QRS komplexu po konec T vlny
- **$AUCqrs$**  – plocha pod křivkou od bodu  $q$  do bodu  $j$ , tedy plocha pod křivkou tvořenou QRS komplexem
- **$AUCst-t$**  – plocha pod křivkou od bodu  $j$  do bodu  $t$ , tedy plocha od konce QRS komplexu po konec T vlny
- **$+AUCqrs$**  – plocha pod křivkou kladné části QRS komplexu


- **$-AUC_{qrs}$**  – plocha pod křivkou záporné části QRS komplexu
- **$+/-AUC_{qrs}$**  – poměr hodnot parametrů  $+AUC_{qrs}$  a  $-AUC_{qrs}$
- **$AUC_{sTamp}$**  – plocha pod křivkou od bodu  $j$  do bodu odpovídajícího amplitudě T vlny
- **$AUC_{TampTend}$**  – plocha pod křivkou od bodu odpovídajícího amplitudě T vlny po bod  $t$ , tedy konec T vlny
- **$sTamp/TampTendAUC$**  – poměr hodnot parametrů  $AUC_{sTamp}$  a  $AUC_{TampTend}$
- **$CEA_{grad}$**  – úhly centrální elektrické osy srdce určené z úseku od bodu  $q$  po  $t$ .  $CEA_{grad} \alpha$  je vypočten z poměru ploch  $AUC_{qrs}$  ze svodu Z a  $AUC_{qrs}$  ze svodu X.  $CEA_{grad} \beta$  je vypočten z poměru ploch  $AUC_{qrs}$  ze svodu Y a  $AUC_{qrs}$  ze svodu X.  $CEA_{grad} \gamma$  je vypočten z poměru ploch  $AUC_{qrs}$  ze svodu Z a  $AUC_{qrs}$  ze svodu Y.
- **$CEA_{qrs}$**  – jsou úhly centrální elektrické osy srdce z oblasti QRS komplexu, mezi body  $q$  a  $j$ .  $CEA_{qrs} \alpha$  je vypočten z poměru ploch  $AUC_{qrs}$  ze svodu Z a  $AUC_{qrs}$  ze svodu X.  $CEA_{qrs} \beta$  je vypočten z poměru ploch  $AUC_{qrs}$  ze svodu Y a  $AUC_{qrs}$  ze svodu X.  $CEA_{qrs} \gamma$  je vypočten z poměru ploch  $AUC_{qrs}$  ze svodu Z a  $AUC_{qrs}$  ze svodu Y.
- **$CEA_{st-t}$**  – jsou úhly centrální elektrické osy srdce získané z úseku mezi body  $j$  a  $t$ . Tedy z úseku od konce QRS komplexu do konce T vlny. Zde jsou opět vypočteny úhly  $\alpha$ ,  $\beta$  a  $\gamma$  stejným způsobem jako v předchozích dvou případech.  $CEA_{st-t} \alpha$  je získán z poměru  $AUC_{st-t}$  ze svodu Z a  $AUC_{st-t}$  ze svodu X, atd.
- **$CEA_{length}$**  – jsou délky vektoru centrální elektrické osy srdce.  $CEA_{length} grad$  je vypočten jako maximum z odmocniny hodnot druhých mocnin úseků mezi body  $q$  a  $t$  (ve svodech X, Y a Z).  $CEA_{length} qj$  je počítán stejným způsobem ale z hodnot vzorků mezi body  $q$  a  $j$ . A konečně  $CEA_{length} jt$  je počítán z hodnot vzorků mezi body  $j$  a  $t$ .

Tyto parametry byly vypočteny pro všechny 3 svody EKG.

Vypočtené parametry jsou znázorněny na následujících obrázcích.



Obr. 23: Znárodnění parametrů QJ, QT, JT, ST10, ST20, ST30, ST40, ST50, jTamp a T amp



Obr. 24: Znázornění parametrů AUCqrst, AUCqrs, +AUCqrs, -AUCqrs, AUCst-t, AUCsTamp a AUCTampTend

### 5.3. Statistické zhodnocení příznaků

Tato kapitola se věnuje popisu vypočtených morfologických parametrů EKG získaných z experimentálních dat.

#### 5.3.1. Testování normality dat

Normální rozložení a homogenita rozptylu jsou nutné podmínky pro korektní použití parametrických statistických testů jako je T-test.


K ověření normálního rozložení parametrů EKG byl použit Shapiro-Wilkův test k ověření normálního rozložení s využitím statistického softwaru Statistica 10.

Z výsledku testu vyplynulo, že hodnoty parametrů EKG nemají normální rozložení a pro otestování, že mezi hodnotami parametrů v kontrolní fázi a v ischemii je rozdíl a je potřeba použít neparametrický test.


#### 5.3.2. Srovnání hodnot parametrů kontrolní fáze vs. ischemie

Na následujících obrázcích jsou pro názornost uvedeny krabicové grafy hodnot jednotlivých vypočtených parametrů svodu X. Krabicový graf parametru v kontrolní fázi je vždy označen číslem 1, krabicový graf parametru v ischemii pak vždy číslem 2. Krabicové grafy parametrů vypočtených z ostatních svodů jsou v příloze č.2.


Krabicové grafy parametrů v ostatních svodech jsou v příloze. Parametry QJ, QT a JT jsou uvedeny pouze jednou, protože se v různých svodech neliší.




Obr. 25: Krabicové grafy parametrů QJ, QT a JT




Obr. 26: Krabicový graf parametru JTamp (svod X)



Obr. 27: Krabicový graf parametru Tamp (svod X)




Obr. 28: Krabicové grafy parametrů ST10, ST20, ST30, ST40, ST50 (svod X)




Obr. 29: Krabicové grafy parametrů AUCqrst, AUCqrs, AUCst-t, +AUCqrs a -AUCqrs (svod X)







Obr. 30: Krabicové grafy parametrů AUCsTamp, AUCTampTend (svod X)



Obr. 31: Krabicové grafy parametrů +/-AUCqrs a sTamp/TendAUC (svod X)



Obr. 32: Krabicové grafy parametrů CEAggrad  $\alpha$ , CEAgqs  $\alpha$  a CEAst-t  $\alpha$



Obr. 33: Krabicové grafy parametru CEAlenght grad

Z uvedených krabicových grafů je patrné, že hodnoty vypočtených parametrů v kontrolní a ischemické fázi se překrývají u všech uvedených parametrů. Z toho vyplývá, že pro klasifikaci srdečního cyklu nebude možné použít pouze jeden z těchto parametrů.

U parametru QJ, který odpovídá délce trvání QRS komplexu je vidět nárůst v ischemii, délka QRS komplexu se tedy v ischemii prodlužuje. Naproti tomu hodnoty parametrů QT a JT klesají, to znamená, že délka srdečního cyklu se v ischemii zkracuje. Hodnoty parametru JTamp (časový úsek od bodu j po vrchol T vlny) pak logicky také klesají. V ischemii dochází také ke snížení amplitudy T vlny (parametr Tamp).

Z parametrů popisujících elevaci/depresi ST úseku (parametry ST10 – ST50) se nejlépe jeví parametr ST20, u kterého se nejvíce liší mediány.

Plochy pod křivkami (AUC) vykazují velký rozptyl hodnot ale jejich mediány se moc neliší.

Hodnoty úhlů centrální elektrické osy srdce také vykazují velký rozptyl a je patrné, že úhly  $\alpha$  a  $\gamma$  (viz. příloha č.2) se v ischemii zvětšují, zatímco hodnoty úhlu  $\beta$  (viz. příloha č.2) v ischemii spíše klesají.

### 5.3.3. Testování rozdílů mezi kontrolní a ischemickou fází

Pro testování rozdílů mezi hodnotami parametrů v kontrolní a ischemické fázi byl použit párový neparametrický Wilcoxonův test. Důvodem použití neparametrického testu je skutečnost, že hodnoty parametrů nemají normální rozložení ani stejné rozptyly, nejsou tedy splněny podmínky pro použití parametrického t-testu.

T je hodnota testové statistiky, Z je rozdíl mezi párovými hodnotami a p-hodnota udává pravděpodobnost, s jakou platí nulová hypotéza, která říká, že mezi hodnotami v kontrolní a ischemické fázi není rozdíl.

Výsledky Wilcoxonova testu jsou v tabulkách 3 a 4.

Tabulka 3: Výsledky Wilcoxonova testu pro parametry QJ, QT a JT

Parametr	T	Z	p-hodnota
QJ	73451	60,133	0,000
QT	4404193	17,191	0,000
JT	2392089	37,330	0,000

Tabulka 4: Výsledky Wilcoxonova testu pro zbývající parametry

Parametr	Svod X			Svod Y			Svod Z		
	T	Z	p-hodnota	T	Z	p-hodnota	T	Z	p-hodnota
JTamp	124708	59,863	0,000	519004	55,864	0,000	4031286	20,178	0,000
ST10	5023545	10,652	0,000	1654642	44,689	0,000	2873448	32,386	0,000
ST20	4853767	12,578	0,000	1476171	46,242	0,000	2989269	31,356	0,000
ST30	4401135	17,279	0,000	2233621	38,925	0,000	2727912	33,775	0,000
ST40	4165085	19,567	0,000	1713244	43,951	0,000	2366351	37,492	0,000
ST50	3926264	22,244	0,000	2209269	39,064	0,000	1995860	41,035	0,000
Tamp	3214247	29,345	0,000	137865	59,785	0,000	2672535	34,708	0,000
AUCqrst	4343222	18,408	0,000	1093152	50,391	0,000	2799648	33,598	0,000
AUCqrs	3963584	22,144	0,000	5290835	9,083	0,000	3454953	27,149	0,000
AUCst-t	4881866	13,107	0,000	539634	55,838	0,000	2896292	32,647	0,000
+AUCqrs	3722338	24,518	0,000	1358094	47,784	0,000	3540827	26,304	0,000
-AUCqrs	<b>6091882</b>	<b>1,200</b>	<b>0,230</b>	5839984	3,679	0,000	3568786	26,029	0,000
+/-AUCqrs	3598801	25,734	0,000	2172490	39,769	0,000	2839714	33,204	0,000
AUCsTamp	4817529	13,740	0,000	163027	59,544	0,000	3168149	29,299	0,000
AUCTampTend	5549493	6,537	0,000	5345627	8,543	0,000	2267117	38,838	0,000
sTamp/TampTendAUC	3137522	30,273	0,000	1168952	49,645	0,000	3097199	30,007	0,000
CEAgrad	4045861	21,334	0,000	5129168	10,674	0,000	2446379	37,074	0,000
CEAqrs	4015204	21,636	0,000	5415878	7,852	0,000	362061	57,585	0,000
CEAst-t	4876756	13,158	0,000	4541969	16,452	0,000	2178788	39,708	0,000
CEAlength	357719	57,628	0,000	357719	57,628	0,000	2530415	36,247	0,000

Z výsledků Wilcoxonova párového testu vyplývá, že existuje statisticky významný rozdíl mezi hodnotami parametrů v kontrolní a ischemické fázi. Jedinou výjimkou je parametr –AUCqrs ve svodu X (zvýrazněno tučně).

#### 5.3.4. Korelace mezi parametry

Lze předpokládat, že mezi některými vypočtenými parametry EKG existuje závislost, že mezi sebou korelují. Z tohoto důvodu byly vypočteny hodnoty korelačního koeficientu mezi parametry a to jak v kontrolní fázi, tak i v ischemii. Korelační matice pro parametry QJ, QT a JT jsou opět uvedeny odděleně. Korelační matice pro svody Y a Z jsou v příloze č.3.

Hodnoty korelace mezi parametry vyšší než 0,8 jsou v tabulkách zdůrazněny tučně.

Tabulka 5: Korelační matice – kontrolní fáze – parametry QJ, QT, JT

	QJ	QT	JT
QJ	<b>1,000</b>	0,773	0,698
QT	0,773	<b>1,000</b>	<b>0,993</b>
JT	0,698	<b>0,993</b>	<b>1,000</b>

Tabulka 6: Korelační matice – ischemická fáze – parametry QJ, QT, JT

	QJ	QT	JT
QJ	<b>1,000</b>	0,148	-0,146
QT	0,148	<b>1,000</b>	<b>0,957</b>
JT	-0,146	<b>0,957</b>	<b>1,000</b>

Velmi vysoká korelace mezi parametry QT a JT v kontrolní i ischemické fázi je pravděpodobně způsobena skutečností, že poloha bodu  $q$  je poměrně stabilní, zatímco polohy bodů  $q$  a  $t$  se výrazně mění a to tak, že s posunem bodu  $q$  k vyšším hodnotám nastává zároveň i posun bodu  $t$ . Hodnoty parametrů QJ a JT tedy rostou nebo klesají zároveň.

	CEAlen gth grad	CEAst-t $\alpha$	CEAqrs $\alpha$	CEAgr ad $\alpha$	sTamp/ TampT endAUC x	AUCTa mpTend d x	AUCsT amp x	+/- AUCqrs s x	- AUCqrs s x	+AUCq rs x	AUCst- t x	AUCqrs s x	AUCqrs st x	Tamp x	ST50 x	ST40 x	ST30 x	ST20 x	ST10 x	JTamp x
JTamp x	-0,212	0,259	-0,374	-0,029	0,042	0,007	0,277	0,196	0,367	-0,079	0,222	-0,012	0,192	-0,114	0,507	0,538	0,567	0,580	0,532	1,000
ST10 x	0,295	-0,132	0,173	-0,247	-0,012	0,530	<b>0,811</b>	0,092	-0,017	0,481	0,764	0,539	0,795	0,390	<b>0,945</b>	<b>0,932</b>	<b>0,948</b>	<b>0,946</b>	<b>1,000</b>	0,532
ST20 x	0,129	-0,165	-0,049	-0,324	-0,020	0,529	<b>0,826</b>	0,191	0,137	0,259	0,775	0,320	0,754	0,391	<b>0,965</b>	<b>0,990</b>	<b>0,978</b>	<b>1,000</b>	<b>0,946</b>	0,580
ST30 x	0,142	-0,210	-0,071	-0,372	-0,019	0,564	<b>0,851</b>	0,193	0,107	0,245	<b>0,803</b>	0,298	0,774	0,433	<b>0,991</b>	<b>0,982</b>	<b>1,000</b>	<b>0,978</b>	<b>0,948</b>	0,567
ST40 x	0,173	-0,230	-0,038	-0,385	-0,023	0,587	<b>0,867</b>	0,171	0,079	0,273	<b>0,822</b>	0,324	0,796	0,461	<b>0,981</b>	<b>1,000</b>	<b>0,982</b>	<b>0,990</b>	<b>0,932</b>	0,538
ST50 x	0,208	-0,276	-0,009	-0,420	-0,025	0,631	<b>0,894</b>	0,155	0,017	0,311	<b>0,853</b>	0,354	<b>0,830</b>	0,511	<b>1,000</b>	<b>0,981</b>	<b>0,991</b>	<b>0,965</b>	<b>0,945</b>	0,507
Tamp x	0,416	<b>-0,878</b>	0,152	<b>-0,837</b>	-0,044	<b>0,948</b>	<b>0,828</b>	-0,101	-0,530	0,412	<b>0,871</b>	0,352	<b>0,845</b>	<b>1,000</b>	0,511	0,461	0,433	0,391	0,390	-0,114
AUCqrst x	0,493	-0,611	0,295	-0,621	-0,019	<b>0,911</b>	<b>0,973</b>	-0,017	-0,367	0,612	<b>0,978</b>	0,613	<b>1,000</b>	0,845	<b>0,830</b>	0,796	0,774	0,754	0,795	0,192
AUCqrs x	0,778	-0,145	<b>0,855</b>	-0,017	0,007	0,405	0,430	-0,264	-0,548	<b>0,988</b>	0,433	<b>1,000</b>	0,613	0,352	0,354	0,324	0,298	0,320	0,539	-0,012
AUCst-t x	0,355	-0,658	0,108	-0,704	-0,023	<b>0,931</b>	<b>0,995</b>	0,051	-0,272	0,435	<b>1,000</b>	0,433	<b>0,978</b>	<b>0,871</b>	<b>0,853</b>	<b>0,822</b>	<b>0,803</b>	0,775	0,764	0,222
+AUCqrs x	0,834	-0,209	<b>0,872</b>	-0,068	0,008	0,430	0,426	-0,353	-0,672	<b>1,000</b>	0,435	<b>0,988</b>	0,612	0,412	0,311	0,273	0,245	0,259	0,481	-0,079
-AUCqrs x	-0,778	0,427	-0,613	0,280	-0,011	-0,382	-0,234	0,638	<b>1,000</b>	-0,672	-0,272	-0,548	-0,367	-0,530	0,017	0,079	0,107	0,137	-0,017	0,367
+/-AUCqrs x	-0,528	0,024	-0,337	-0,031	-0,005	0,026	0,058	<b>1,000</b>	0,638	-0,353	0,051	-0,264	-0,017	-0,101	0,155	0,171	0,193	0,191	0,092	0,196
AUCsTamp x	0,346	-0,608	0,095	-0,667	-0,024	<b>0,890</b>	<b>1,000</b>	0,058	-0,234	0,426	<b>0,995</b>	0,430	<b>0,973</b>	<b>0,828</b>	<b>0,894</b>	<b>0,867</b>	<b>0,851</b>	<b>0,826</b>	<b>0,811</b>	0,277
AUCTampTend x	0,353	-0,776	0,145	-0,772	-0,018	1,000	<b>0,890</b>	0,026	-0,382	0,430	0,931	0,405	<b>0,911</b>	<b>0,948</b>	0,631	0,587	0,564	0,529	0,530	0,007
sTamp/TampTend AUC x	0,011	0,029	0,013	0,028	<b>1,000</b>	-0,018	-0,024	-0,005	-0,011	0,008	-0,023	0,007	-0,019	-0,044	-0,025	-0,023	-0,019	-0,020	-0,012	0,042
CEAgrad $\alpha$	-0,079	<b>0,861</b>	0,243	<b>1,000</b>	0,028	-0,772	-0,667	-0,031	0,280	-0,068	-0,704	-0,017	-0,621	-0,837	-0,420	-0,385	-0,372	-0,324	-0,247	-0,029
CEAqrs $\alpha$	<b>0,804</b>	-0,029	<b>1,000</b>	0,243	0,013	0,145	0,095	-0,337	-0,613	<b>0,872</b>	0,108	<b>0,855</b>	0,295	0,152	-0,009	-0,038	-0,071	-0,049	0,173	-0,374
CEAst-t $\alpha$	-0,235	<b>1,000</b>	-0,029	<b>0,861</b>	0,029	-0,776	-0,608	0,024	0,427	-0,209	-0,658	-0,145	-0,611	-0,878	-0,276	-0,230	-0,210	-0,165	-0,132	0,259
CEAlength grad	<b>1,000</b>	-0,235	0,804	-0,079	0,011	0,353	0,346	-0,528	-0,778	<b>0,834</b>	0,355	0,778	0,493	0,416	0,208	0,173	0,142	0,129	0,295	-0,212

Tabulka 7: Korelační matice – kontrolní fáze – svod X

	CEAlen ght grad	CEAst- t $\alpha$	CEAqrs $\alpha$	CEAgr ad $\alpha$	sTamp/ TampT endAUC x	AUCTa mpTen d x	AUCsT amp x	+/- AUCqr s x	- AUCqr s x	+AUCq rs x	AUCst- t x	AUCqr s x	AUCqr st x	Tamp x	ST50 x	ST40 x	ST30 x	ST20 x	ST10 x	JTamp x
JTamp x	-0,052	-0,284	-0,311	-0,408	0,043	0,438	0,030	-0,024	0,401	0,267	0,277	0,340	0,380	0,127	0,471	0,487	0,467	0,326	0,076	<b>1,000</b>
ST10 x	0,524	-0,331	-0,292	-0,420	0,002	0,492	0,073	0,455	0,413	0,590	0,342	0,586	0,558	<b>0,810</b>	0,459	0,562	0,709	<b>0,912</b>	<b>1,000</b>	0,076
ST20 x	0,380	-0,401	-0,418	-0,534	0,005	0,683	0,283	0,361	0,560	0,591	0,576	0,638	0,754	<b>0,845</b>	0,750	<b>0,834</b>	<b>0,927</b>	<b>1,000</b>	<b>0,912</b>	0,326
ST30 x	0,227	-0,398	-0,487	-0,565	0,005	0,769	0,451	0,203	0,640	0,538	0,722	0,626	<b>0,852</b>	0,779	<b>0,929</b>	<b>0,974</b>	<b>1,000</b>	<b>0,927</b>	0,709	0,467
ST40 x	0,136	-0,357	-0,486	-0,539	0,003	0,792	0,534	0,083	0,644	0,482	0,782	0,586	<b>0,874</b>	0,715	<b>0,984</b>	<b>1,000</b>	<b>0,974</b>	<b>0,834</b>	0,562	0,487
ST50 x	0,063	-0,306	-0,454	-0,492	0,000	<b>0,809</b>	0,595	-0,002	0,613	0,431	<b>0,826</b>	0,537	<b>0,880</b>	0,678	<b>1,000</b>	<b>0,984</b>	<b>0,929</b>	0,750	0,459	0,471
Tamp x	0,254	-0,187	-0,240	-0,321	-0,011	0,714	0,533	0,138	0,394	0,442	0,738	0,468	0,780	<b>1,000</b>	0,678	0,715	0,779	<b>0,845</b>	<b>0,810</b>	0,127
AUCqrst x	0,259	-0,232	-0,413	-0,435	-0,002	<b>0,836</b>	0,619	0,093	0,659	0,656	<b>0,857</b>	0,721	<b>1,000</b>	0,780	<b>0,880</b>	<b>0,874</b>	<b>0,852</b>	0,754	0,558	0,380
AUCqrs x	0,578	-0,274	-0,482	-0,483	0,002	0,411	0,022	0,424	<b>0,804</b>	<b>0,961</b>	0,261	<b>1,000</b>	0,721	0,468	0,537	0,586	0,626	0,638	0,586	0,340
AUCst-t x	-0,070	-0,120	-0,218	-0,247	-0,004	<b>0,859</b>	<b>0,846</b>	-0,185	0,321	0,199	<b>1,000</b>	0,261	<b>0,857</b>	0,738	<b>0,826</b>	0,782	0,722	0,576	0,342	0,277
+AUCqrs x	0,734	-0,202	-0,309	-0,381	-0,005	0,388	-0,061	0,497	0,607	<b>1,000</b>	0,199	<b>0,961</b>	0,656	0,442	0,431	0,482	0,538	0,591	0,590	0,267
-AUCqrs x	0,083	-0,350	-0,717	-0,567	0,016	0,347	0,194	0,147	<b>1,000</b>	0,607	0,321	<b>0,804</b>	0,659	0,394	0,613	0,644	0,640	0,560	0,413	0,401
+/-AUCqrs x	0,471	-0,298	-0,036	-0,208	-0,004	-0,051	-0,274	<b>1,000</b>	0,147	0,497	-0,185	0,424	0,093	0,138	-0,002	0,083	0,203	0,361	0,455	-0,024
AUCsTamp x	-0,245	0,054	-0,089	-0,024	-0,006	0,454	<b>1,000</b>	-0,274	0,194	-0,061	<b>0,846</b>	0,022	0,619	0,533	0,595	0,534	0,451	0,283	0,073	0,030
AUCTampTend x	0,114	-0,252	-0,278	-0,388	0,000	<b>1,000</b>	0,454	-0,051	0,347	0,388	<b>0,859</b>	0,411	<b>0,836</b>	0,714	<b>0,809</b>	0,792	0,769	0,683	0,492	0,438
sTamp/TampTendAUC x	-0,025	0,008	-0,013	0,004	<b>1,000</b>	0,000	-0,006	-0,004	0,016	-0,005	-0,004	0,002	-0,002	-0,011	0,000	0,003	0,005	0,005	0,002	0,043
CEAgrad $\alpha$	-0,184	<b>0,899</b>	0,519	<b>1,000</b>	0,004	-0,388	-0,024	-0,208	-0,567	-0,381	-0,247	-0,483	-0,435	-0,321	-0,492	-0,539	-0,565	-0,534	-0,420	-0,408
CEAqrs $\alpha$	0,052	0,392	<b>1,000</b>	0,519	-0,013	-0,278	-0,089	-0,036	-0,717	-0,309	-0,218	-0,482	-0,413	-0,240	-0,454	-0,486	-0,487	-0,418	-0,292	-0,311
CEAst-t $\alpha$	-0,100	<b>1,000</b>	0,392	<b>0,899</b>	0,008	-0,252	0,054	-0,298	-0,350	-0,202	-0,120	-0,274	-0,232	-0,187	-0,306	-0,357	-0,398	-0,401	-0,331	-0,284
CEAlenght grad	<b>1,000</b>	-0,100	0,052	-0,184	-0,025	0,114	-0,245	0,471	0,083	0,734	-0,070	0,578	0,259	0,254	0,063	0,136	0,227	0,380	0,524	-0,052

Tabulka 8: Korelační matice – ischemická fáze – svod X

Z uvedených korelačních matic vyplývá, že existuje silná korelace ( $r > 0,8$ ) mezi parametry ST10, ST20, ST30, ST40 a ST50 a to ve všech svodech v kontrolní a ischemické fázi. Důvodem je zřejmě to, že roste nebo klesá úroveň celého ST úseku a změny se tedy projevují ve všech ST parametrech podobně.

Dále jsou vysoce korelované parametry AUCsTamp (plocha pod křivkou od bodu  $j$  po vrchol T vlny) a AUCst-t s parametry ST a Tamp, protože tyto parametry se nacházejí v úseku EKG křivky, ze které se tyto parametry vypočítávají.


Parametr JTamp je poměrně málo korelovaný ve všech svodech a to v kontrolní i ischemické fázi. Je tedy pravděpodobné, že by měl být velmi přínosný pro klasifikaci.

Logicky je také silná korelace mezi parametry popisujícími úhly centrální elektrické osy srdce a plochami pod křivkou, ze kterých jsou tyto úhly vypočteny - např. korelace mezi parametry CEAqrs a AUCqrs.


Výsledky korelace celkově naznačují, že některé vypočtené parametry mohou být nadbytečné. Hodnoty korelačního koeficientu mezi parametry v ischemické fázi jsou obecně nižší, může to být způsobeno větším rozptylem hodnoty parametrů v ischemii.

### 5.3.5. Rozdíly hodnot parametrů mezi různými zvířaty


V této kapitole jsou uvedeny krabicové grafy hodnot některých vybraných parametrů (QJ, ST20 x a Tamp x ) změřených na různých králících srdcích. Byla k dispozici data změřená na 6 různých králících srdcích.




Obr. 34: Krabicové grafy hodnot parametru QJ pro různé králíky – kontrolní fáze



Obr. 35: Krabicové grafy hodnot parametru QJ pro různé králíky – ischemická fáze




Obr. 36: Krabicové grafy hodnot parametru ST20 (svod X) pro různé králíky – kontrolní fáze




Obr. 37: Krabicové grafy hodnot parametru ST20 (svod X) pro různé králíky – ischemická fáze





Obr. 38: Krabicové grafy hodnot parametru Tamp (svod X) pro různé králíky – kontrolní fáze



Obr. 39: Krabicové grafy hodnot parametru Tamp (svod X) pro různé králíky – ischemická fáze

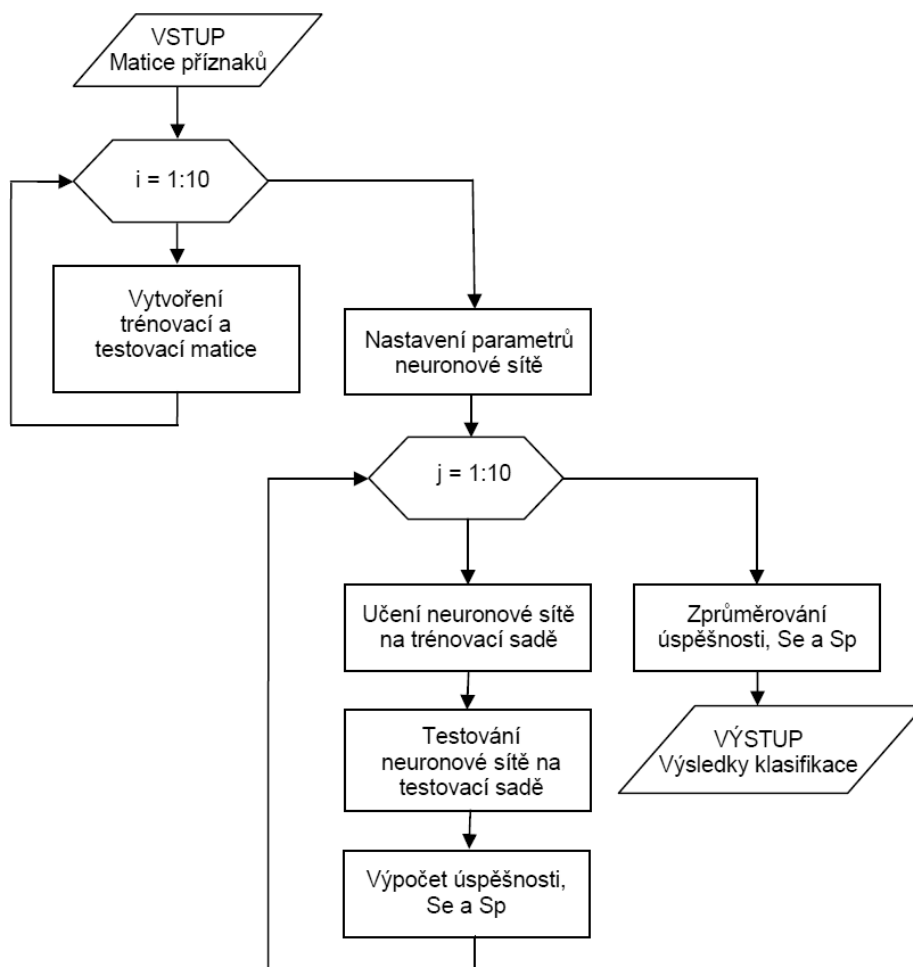
Z výše uvedených krabicových grafů je patrné, že mezi hodnotami parametrů změřenými u různých králíků existují rozdíly. Tyto rozdíly jsou mnohem výraznější v ischemické fázi než v kontrolní. Srdce různých králíků tedy reagují na ischemii individuálně, což může komplikovat správnou klasifikaci srdečních cyklů.

## 5.4. Použitý klasifikátor

Pro vlastní klasifikaci srdečních cyklů na ischemické a normální byla jako klasifikátor použita vícevrstvá neuronová síť.

Tento klasifikátor byl realizován v programovém prostředí Matlab.

Byly vytvořeny dvě varianty: v první variantě byly jako vektor klasifikačních příznaků použity všechny vypočtené parametry EKG. Vývojový diagram programu je na obrázku 38.



Obr. 40: Vývojový diagram – klasifikace s využitím všech parametrů EKG

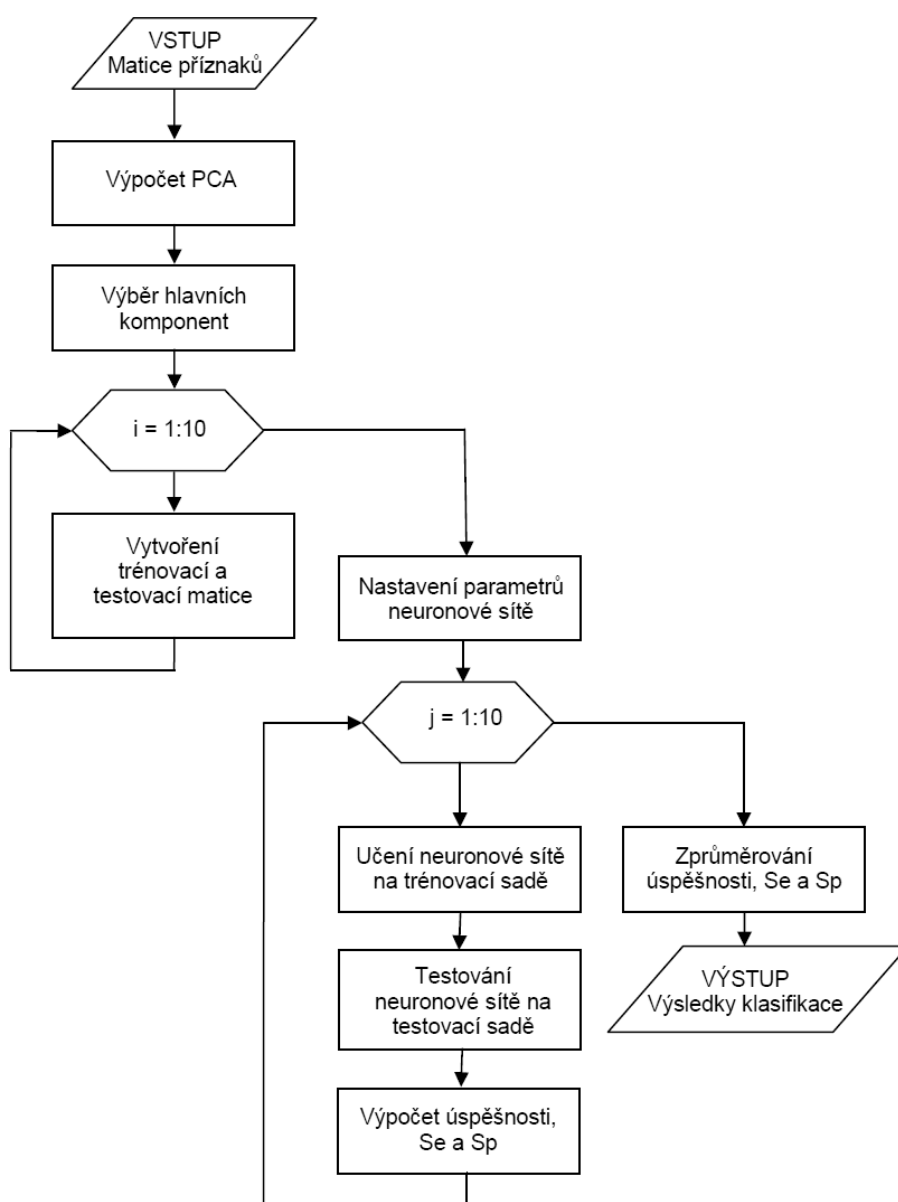
V této variantě tvoří vstupní matici klasifikačních příznaků všechny vypočtené parametry EKG (sloupce matice) a všechny dostupné srdeční cykly.

V dalším kroku jsou data rozdělena do trénovací a testovací matice a dále nastaveny výchozí parametry klasifikátoru (neuronové sítě). Následuje učení neuronové sítě na trénovací matici a pak testování naučené sítě na datech z testovací matice a pak je vypočtena úspěšnost klasifikace, specifická a senzitivita.

Data jsou do trénovací a testovací matice rozdělována náhodně v pevně daném poměru a výběr je v cyklu *for* opakován 10x.

Následující učení neuronové sítě a klasifikace pak opět probíhá 10x v cyklu *for* pro každou vytvořenou trénovací a testovací matici. Všechny získané dílčí výsledky jsou pak zprůměrovány. Důvodem tohoto postupu je snaha o omezení jak vlivu výběru dat to trénovací a testovací matice na výsledky klasifikace, tak i omezení vlivu náhodného výchozího nastavení hodnot prahů a vah neuronů v neuronové síti (viz kapitola 4.3.1).

Ve druhé variantě je na vstupní matici klasifikačních příznaků nejprve provedena analýza hlavních komponent, dále je vybrán zvolený počet hlavních komponent a dále už program pracuje stejně jako v předchozím případě. Vývojový diagram programu je na obrázku 36. Data byla před vlastním výpočtem analýzy hlavních komponent standardizována.



Obr. 41: Vývojový diagram – klasifikace s využitím analýzy hlavních komponent


Pro vytvoření neuronové sítě v Matlabu byla použita funkce `feedforwardnet`, která je součástí Neural Network Toolboxu,

```
net = feedforwardnet(Hiddensize, TrainFcn)
```

kde parametr `Hiddensize` je počet neuronů ve skryté vrstvě a `TrainFcn` je algoritmus optimalizace hodnot vah a prahů sítě. V této práci byl vyzkoušen algoritmus gradientního sestupu (`traingd`) a algoritmus gradientního sestupu s adaptivním krokem učení (`traingda`). Protože neexistuje způsob, jak jednoznačně určit vhodný počet neuronů ve skryté vrstvě, byly vyzkoušeny různé počty neuronů. Konkrétně 10, 20, 30 a 50 neuronů. Neurony ve skryté vrstvě využívají sigmoidní aktivační funkci a ve výstupní vrstvě je použita skoková aktivační funkce.

Učení sítě algoritmem gradientního sestupu je popsáno v kapitole 4.3.1. U algoritmu gradientního sestupu s adaptivním krokem učení (`traingda`) se krok učení sníží, pokud je poměr chyby sítě v současném a předchozím kroku větší než 1,04 a nové hodnoty prahů a vah se neuloží. Pokud je naopak poměr chyby sítě v současném a předchozím kroku menší než 0,7, krok učení se zvýší.

Grafy závislosti chyby sítě na učebních datech v závislosti na počtu epoch učení pro oba použité algoritmy učení jsou na Obr. 42.



Obr. 42: Chyba sítě v závislosti na počtu epoch učení: a) `traingd` b) `traingda`

Dále byly nastaveny tyto parametry sítě:

- `net=init(net)` – náhodné nastavení výchozích hodnot prahů a vah neuronů
- `net.performFcn = 'mse'` – nastavení výpočtu chyby sítě na střední kvadratickou odchylku (viz. kapitola 4.3.3)
- `net.trainParam.Epoch = 300` – nastavení počtu epoch učení (nastavováno v rozsahu 20 - 300 epoch učení)
- `net.trainParam.lr = 0.1` – nastavení kroku učení
- `net.divideFcn = ''` – odstranění rozdělení dat z učební matice na učební, validační a testovací množinu (všechna data z učební matice byla použita pro učení)

sítě, testovací množina byla sestavena zvlášť z příznakových vektorů neobsažených v učební množině).

## **5.5. Výsledky klasifikace a diskuse dosažených výsledků**

Vlastní klasifikace srdečních cyklů na ischemické a kontrolní probíhala s využitím programu v Matlabu (viz kapitola 5.4). Celkem bylo použito 9970 srdečních cyklů, vždy 4985 cyklů z kontrolní a 4985 cyklů z ischemické fáze.

Z celkového počtu 9970 srdečních cyklů bylo pro trénování neuronové sítě použito 8000 náhodně vybraných cyklů, zbývajících 1970 cyklů bylo použito pro ověření úspěšnosti klasifikace. Náhodný výběr srdečních cyklů do učební a testovací množiny dat probíhal vždy 10x, stejně tak probíhala následná klasifikace srdečních cyklů 10x pro každou vytvořenou učební a testovací množinu, klasifikace tedy probíhala celkem 100x pro každé nastavení klasifikátoru. Důvodem tohoto postupu bylo omezení vlivu náhodného rozdělení dat do učební a testovací množiny a také snížení vlivu náhodně zvolených počátečních hodnot prahů a vah neuronové sítě na proces učení sítě a následné výsledky klasifikace (viz kapitola 4.3.1).

V následujících kapitolách jsou uvedeny zprůměrované hodnoty celkové úspěšnosti klasifikace, senzitivity a specifity pro různá nastavení klasifikátoru.

### **5.5.1. Morfologické parametry**

V tomto případě byly jako vektor klasifikačních příznaků použity všechny vypočtené parametry EKG s využitím všech 3 svodů, celkem 63 parametrů.

Nastavení sítě, při němž bylo dosaženo úspěšnosti klasifikace vyšší než 99% je vyznačeno tučně, hodnoty senzitivity a specifity jsou pro přehlednost uvedeny kurzívou.

Krok učení sítě byl nastaven na 0,1 a pro optimalizaci hodnot prahů a vah neuronů byla v prvním případě použita metoda gradientního sestupu (traingd - tabulka 9) a v druhém případě metoda gradientního sestupu s adaptivním krokem učení (traingda - tabulka 10).

V následujících tabulkách jsou uvedeny hodnoty senzitivity, specifity a úspěšnosti klasifikace pro různá nastavení klasifikátoru.

Tabulka 9: Ukazatele úspěšnosti klasifikace [%] pro různý počet epoch učení a neuronů ve skryté vrstvě (traingd)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	87,7	97,5	92,5	90,8	97,4	94,0	91,3	97,9	94,5	88,7	97,5	92,8
50	96,5	98,8	97,6	96,9	98,9	97,9	96,4	99,0	97,6	94,9	98,2	96,5
100	98,9	99,6	<b>99,2</b>	99,1	99,8	<b>99,4</b>	99,3	99,6	<b>99,4</b>	97,9	99,3	98,6
200	99,7	99,9	<b>99,8</b>	99,8	99,9	<b>99,8</b>	99,8	100	<b>99,9</b>	99,6	99,9	<b>99,7</b>
300	99,8	99,9	<b>99,9</b>	99,9	100	<b>99,9</b>	99,9	99,9	<b>99,9</b>	99,8	99,9	<b>99,9</b>

Tabulka 10: Ukazatele úspěšnosti klasifikace [%] pro různý počet epoch učení a neuronů ve skryté vrstvě (traingda)


Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	93,3	97,6	95,4	94,2	97,5	95,5	92,1	97,5	94,5	87,9	90,6	90,3
50	99,1	99,4	<b>99,1</b>	97,4	99,4	98,3	96,8	98,5	97,4	95,5	98,4	96,4
100	99,9	99,7	<b>99,8</b>	99,3	99,6	<b>99,4</b>	99,1	99,8	<b>99,3</b>	99,0	99,5	98,9
200	99,9	99,9	<b>99,9</b>	99,9	99,9	<b>99,9</b>	99,7	99,8	<b>99,8</b>	99,4	99,9	<b>99,4</b>
300	99,9	99,9	<b>99,9</b>	99,9	99,9	<b>99,9</b>	99,8	99,9	<b>99,9</b>	99,6	99,9	<b>99,8</b>

Z výše uvedených tabulek je patrné, že klasifikátor dosahuje při maximálním počtu epoch učení (300) celkové úspěšnosti klasifikace, senzitivity i specificity až 99,9%. Počet neuronů ve skryté vrstvě ani použitý algoritmus pro optimalizaci nastavení vah a prahů neuronů nemá na výsledky velký vliv. Rovněž není z výsledků patrné, že by došlo k přeučení sítě. Důvodem, proč nebylo dosaženo 100% úspěšnosti klasifikace může být skutečnost, že některé srdeční cykly se výrazně liší od ostatních.

### 5.5.2. Hlavní komponenty vypočtené z morfologických parametrů

Analýza hlavních komponent (viz kapitola 4.2.5) byla použita ke snížení počtu parametrů v klasifikačním vektoru.

Pro zjištění počtu hlavních komponent, které bude nutné vybrat do vektoru klasifikačních příznaků byl vytvořen tzv. scree plot (Obr. 43), kde na vodorovné ose jsou indexy vypočtených hlavních komponent a na svislé ose jsou pak hodnoty jejich vlastních čísel.



Obr. 43: Scree plot

Tabulka 11 dále uvádí přesné hodnoty vlastních čísel vypočtených hlavních komponent a také variabilitu vyčerpanou jednotlivými hlavními komponentami a kumulovanou sumu vyčerpané variability.

Tabulka 11: Hodnoty vlastních čísel a vyčerpaná variabilita

Hlavní komponenta	Hodnota vlastního čísla	Vyčerpaná variabilita [%]	Kumulovaná suma vyčerpané variability [%]
1	20,122	31,94	31,94
2	10,987	17,43	49,38
3	6,337	10,05	59,43
4	5,003	7,94	67,38
5	3,333	5,29	72,67
6	3,170	5,03	77,70
7	1,921	3,05	80,75
8	1,523	2,41	83,17
9	1,310	2,07	85,25
10	0,999	1,58	86,84
11	0,998	1,58	88,42
12	0,905	1,43	89,86
13	0,829	1,31	91,18
14	0,650	1,03	92,21
15	0,619	0,98	93,19

Z výše uvedené tabulky je vidět, že prvních 7 hlavních komponent vyčerpává více než 80% variability původních dat a prvních 9 hlavních komponent má hodnoty vlastního čísla vyšší než 1. Těchto 9 hlavních komponent pak vyčerpává přibližně 85% variability.

V následujících tabulkách jsou uvedeny hodnoty dosažené senzitivity, specifity a úspěšnosti klasifikace pro různá nastavení klasifikátoru a různý počet vybraných hlavních komponent.

Krok učení neuronové sítě byl opět nastaven na 0,1 a pro optimalizaci hodnot prahů a vah neuronů sítě byly použity metody gradientního sestupu (traingd) a metoda gradientního sestupu s adaptivním krokem učení (traingda). Pro přehlednost jsou zde uvedeny jen výsledky při nastavení 300 epoch učení sítě. Výsledky při jiných nastaveních počtů epoch učení jsou v příloze č. 4.

Tabulka 12: Ukazatele úspěšnosti klasifikace [%] pro různý počet epoch učení a neuronů ve skryté vrstvě

	Počet neuronů ve skryté vrstvě											
Algoritmus optimalizace vah a prahů	10			20			30			50		
3 hlavních komponenty												
	Se	Sp		Se	Sp		Se	Sp		Se	Sp	
Traindg	84,0	93,0	88,4	85,6	92,0	88,8	88,0	92,5	90,1	91,2	94,0	92,5
Traingda	89,1	92,7	90,8	91,7	92,9	92,3	91,0	94,6	92,7	91,6	93,7	92,5
5 hlavních komponent												
Traindg	91,1	96,0	93,4	94,7	96,6	95,3	95,0	97,0	95,8	96,9	97,5	96,8
Traingda	95,6	96,8	96,0	96,8	97,5	97,0	97,1	98,1	97,3	97,3	97,4	97,1
7 hlavních komponent												
Traindg	93,0	97,8	95,3	94,9	98,6	96,7	96,0	98,5	97,0	97,8	99,0	98,2
Traingda	98,5	98,6	98,6	98,5	98,8	98,5	98,9	99,2	98,9	98,4	99,2	98,7
8 hlavních komponent												
Traindg	92,4	97,4	95,0	94,6	97,7	96,0	95,8	98,0	96,6	98,2	99,0	98,4
Traingda	98,4	99,3	98,8	98,8	99,4	99,0	97,3	99,0	98,0	97,9	98,8	98,2
9 hlavních komponent												
Traindg	93,2	97,5	95,3	96,4	98,4	97,3	96,8	98,7	97,6	98,0	98,7	98,2
Traingda	98,6	98,8	98,6	98,6	99,0	98,7	98,6	99,1	98,8	98,1	98,9	98,3

Z tabulky 12 je vidět, že nejlepších výsledků bylo dosaženo při použití prvních 7 až 9 hlavních komponent, to je v souladu s teoretickými předpoklady uvedenými v kapitole 4.2.5. Algoritmus gradientního sestupu s adaptivním krokem učení (traingda) dává v tomto případě lepší výsledky, než algoritmus gradientního sestupu s pevným krokem učení (traingd), algoritmus s adaptivním krokem učení také dosahuje dobrých výsledků po menším počtu epoch učení (viz příloha č.4), to je očekávaný výsledek.

Při porovnání těchto výsledků klasifikace s výsledky získanými při stejných nastaveních klasifikátoru s využitím všech vypočtených parametrů (kapitola 5.5.1, tabulka 9 a 10) je zřejmé zhoršení všech sledovaných parametrů klasifikace. To tedy znamená, že v důsledku použití analýzy hlavních komponent na testovaná data došlo ke ztrátě informací důležitých pro klasifikaci. To může být způsobeno tím, že analýza hlavních komponent předpokládá normální rozložení hodnot parametrů, což dostupná data nesplňují a vlivem odlehklých hodnot.



Nejlepších výsledků bylo dosaženo při použití prvních 8 hlavních komponent, kdy bylo dosaženo celkové úspěšnosti klasifikace až 99%, senzitivity 98,8% a specifity 99,4%. Stejně jako v předchozím případě, ani zde není patrné přeučení sítě a nejlepších výsledků bylo dosaženo při maximálním počtu 300 epoch učení sítě. Nejlepších výsledků bylo opět dosaženo při použití 20 neuronů ve skryté vrstvě, při vyšším počtu neuronů je už síť pro tuto klasifikační úlohu příliš složitá a hrozí její přeučení (overfitting).

Použití analýzy hlavních komponent na analyzovaná data by bylo vhodné zejména, pokud při velmi velkém objemu analyzovaných dat, kdy by se projevil kratší čas běhu programu a zároveň by došlo jen k malému zhoršení výsledků klasifikace. Tato metoda by také mohla být vhodná, pokud by analyzovaná data obsahovala větší množství šumu. Je pravděpodobné, že v datech použitých v této práci hlavní komponenty vynechané z klasifikace obsahují důležité informace. To může vysvětlovat zhoršení výsledků klasifikace oproti klasifikaci s využitím původních morfologických parametrů. Vzhledem k tomuto poklesu úspěšnosti klasifikace tedy nelze jednoznačně říci, že by některé vypočtené parametry EKG byly nadbytečné.

Celkově lze říci, že získané výsledky jsou přibližně srovnatelné s výsledky u ostatních autorů (tabulka 13), avšak toto srovnání není úplně přesné, protože v tomto případě byla použita experimentální data získaná z měření na izolovaných zvířecích srdcích, kde jsou rozdíly mezi neischemickými a ischemickými srdečními cykly velmi výrazné. Výsledky použití navržené metody na datech získaných z reálných pacientů by se mohly částečně lišit, pravděpodobně by došlo k určitému zhoršení výsledků.

Tabulka 13: Ukazatele úspěšnosti detekce ischemických úseků - výsledky jiných autorů

Autoři	Rok	Se	Sp	P+	Úsp
M. Llamendo, J. P. Martinez [24]	2011	95%	-	98%	93%
L. Dranca, A. Goni, A. Illarramendi[25]	2013	81,2%	-	74,8%	-
M. Llamendo, J. P. Martinez, M. Albertal, D. Romero, E. Pueyo, P. Laguna [26]	2013	100%	91%	-	-

## 6. Závěr

Úkolem této práce bylo provést literární rešerši o možnostech automatické detekce ischemie v experimentálních EKG záznamech.

V práci jsou uvedeny projevy ischemie v EKG signálu a stručně popsány metody umožňující vytvoření vektoru příznaků z EKG signálu pro jeho následnou klasifikaci.

Dále byly vypočteny morfologické parametry EKG z dostupných signálů s využitím programu v Matlabu. K tomuto účelu byla použita experimentální data změřená na izolovaných králičích srdcích, která jsou dostupná na UBMI.

Následně bylo provedeno statistické zhodnocení těchto vypočtených parametrů. Pro názornost jsou uvedeny krabicové grafy hodnot všech vypočtených parametrů v kontrolní i ischemické fázi. Wilcoxonův párový test byl použit k ověření skutečnosti, že mezi hodnotami parametrů v kontrolní a ischemické fázi je rozdíl a lze je tedy použít pro klasifikaci. Výsledky testu naznačují, že tomu tak skutečně je. Byly také vytvořeny matice korelací mezi parametry, jejich smyslem je odhalit, které parametry jsou závislé a mohou tedy být nadbytečné. Byly zjištěny vysoké hodnoty korelace mezi řadou parametrů, avšak výsledky klasifikace nenaznačují, že některé parametry byly skutečně nadbytečné. Dokladem toho může být zhoršení výsledků klasifikace v případě, kdy byla použita analýza hlavních komponent pro redukci délky vektoru klasifikačních příznaků.

Ve vypočtených morfologických parametrech jsou patrné očekávané projevy ischemie. V souladu s teoretickými předpoklady dochází v ischemické fázi k rozšíření QRS komplexu (parametr QJ), poklesu amplitudy či inverzi T vlny (parametr Tamp), zkrácení srdečního cyklu (parametry JT a QJ), změnám v amplitudě ST úseku (zejména parametry ST20 a ST30). Objevují se také změny v úhlech centrální osy srdce (nárůst úhlů  $\alpha$  a  $\gamma$  a pokles úhlu  $\beta$ ) a změny plochách pod křivkou různých částí EKG křivky.

Zjištěn byl také poměrně velký rozdíl v hodnotách vypočtených parametrů u různých měřených zvířat, a to zejména v ischemické fázi.

Pro vlastní klasifikaci srdečních cyklů byla v Matlabu vytvořena vícevrstvá dopředná neuronová síť. V případě, že byly jako klasifikační příznakový vektor použity všechny vypočtené parametry EKG, bylo při vhodném nastavení klasifikátoru dosaženo celkové úspěšnosti klasifikace až 99,9%. V případě použití analýzy hlavních komponent pro redukci velikosti příznakového klasifikačního vektoru došlo k určitému poklesu celkové úspěšnosti klasifikace na 99%.

Rovněž byly vyzkoušeny dva různé trénovací algoritmy pro učení neuronové sítě, a to metoda gradientního sestupu a metoda gradientního sestupu s adaptivním krokem učení. Z těchto dvou metod bylo dosaženo lepších výsledků s použitím druhé jmenované metody. Počet neuronů skryté vrstvy sítě byl stanoven empiricky, přičemž nejlepších výsledků bylo dosaženo s použitím 10 až 30 neuronů.

Získané výsledky jsou přibližně srovnatelné s výsledky jiných autorů, avšak více vypovídající výsledky o úspěšnosti této metody by bylo možné získat, pokud by byla k dispozici i data získaná od skutečných pacientů.

## 7. Literatura

- [1] ŠTĚPÁNKOVÁ, O. *Elektrokardiografie, vznik a měření signálů*. [online]. s. 17 [cit. 2013-12-07] Dostupné z: [http://gerstner.felk.cvut.cz/biolab/X33BMI/slides/cviceni\\_3\\_EKG\\_pozn.pdf](http://gerstner.felk.cvut.cz/biolab/X33BMI/slides/cviceni_3_EKG_pozn.pdf)
- [2] KOLLÁTOROVÁ, H. EKG a EEG. [online]. 2009, s. 50 [cit. 2013-12-09]. Dostupné z: [http://www.szymb.cz/admin/upload/sekce\\_materialy/EKG\\_a\\_EEG.pdf](http://www.szymb.cz/admin/upload/sekce_materialy/EKG_a_EEG.pdf)
- [3] KOLÁŘ, R. *Lékařská Diagnostická technika*. Vysoké učení technické v Brně, 2006.
- [4] MACLEOD, R., BIRCHLER, B.. *ECG Measurement and Analysis* [online]. 2011 [cit. 2013-11-2] Dostupné z: <http://www.sci.utah.edu/~macleod/bioen/be6000/labnotes/ecg/figures/frankleads.jpg>
- [5] Proper Placement of 6 Chest Leads [online]. 2012 [cit. 2013-11-1] Dostupné z: <http://ecg.utah.edu/img/items/Chest%20lead%20placement.jpg>
- [6] Posterior Myocardial Infarction [online]. 2011 [cit. 2013-11-2] Dostupné z: <http://cdn.lifeinthefastlane.com/wp-content/uploads/2011/09/ST-segment-V2-PMI.jpg>
- [7] CHANNER, K., MORRIS, F. *ABC of clinical electrocardiography: Myocardial ischaemia* [online]. 2002 [cit 2013-11-6] Dostupné z: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC1122957/>
- [8] HAMAN, P. *Ischemická choroba srdeční* [online]. 2013 [cit 2013-11-6] Dostupné z: <http://ekg.kvalitne.cz/ichs.htm>
- [9] CLIFFORD, G. D., AZUAJE, F., MCSHARRY, P. *Advanced methods and tools for ECG data analysis*. Boston: Artech House, 2006, 384 s. ISBN 1-58053-966-1.
- [10] PhysioNet, *MIT-BIH Arrhythmia Database* [online]. 2012 [cit 2013-11-8] Dostupné z: <http://www.physionet.org/physiobank/database/mitdb/>

- [11] MANOCHA, A. K., MANDEEP, S. *An Overview of Ischemia Detection Techniques*, International Journal of Scientific & Engineering Research [online]. 2011 [cit 2013-11-8] Dostupné z: <http://www.ijser.org/researchpaper%5CAn-Overview-of-Ischemia-Detection-Techniques.pdf>
- [12] JARKOVSKÝ, J., LITTNEROVÁ, S. *Pokročilé statistické metody*, Masarykova univerzita Brno. Učební text, 2011.
- [13] ŠÍMA, J.; NERUDA, R.: *Teoretické otázky neuronových sítí*. Matfyzpress, Praha, 1996. ISBN: 80-85863-18-9
- [14] VONDRÁK, I.: *Neuronové sítě*. Fakulta elektrotechniky a informatiky VŠB. [online]. 2009 [cit 2013-11-10] Dostupné z: [http://vondrak.cs.vsb.cz/download/Neuronove\\_site.pdf](http://vondrak.cs.vsb.cz/download/Neuronove_site.pdf)
- [15] KELBEL, J., ŠILHÁN, D.: *Shluková analýza*, ČVUT Fakulta Dopravní [online] [cit 2013-11-10] Dostupné z: <http://www.fd.cvut.cz/personal/nagyivan/Projekty/Classification/ShlukovaAnalyza.pdf>
- [16] *Heart Rate Variability*, American Heart Association [online]. 1996 [cit 2013-11-11] Dostupné z: <http://circ.ahajournals.org/content/93/5/1043.full#T2>
- [17] TARVAINEN, M. P., NISKANEN, J. P. USER'S GUIDE, Kubios HRV version 2.1. [online]. 2012, [cit. 2013-11-11]. Dostupné z: [http://kubios.uef.fi/media/Kubios\\_HRV\\_2.1\\_Users\\_Guide.pdf](http://kubios.uef.fi/media/Kubios_HRV_2.1_Users_Guide.pdf)
- [18] KOZUMPLÍK, J., *Pokročilá analýza biologických signálů (FACS)*, přednášky z předmětu, VUT Brno [online]. 2013 [cit. 2013-11-20]
- [19] MENOWN, I. B. A, ALLEN, J., ANDERSON, J. McC., ADGEDY, A. A. J. *ST depression only on the initial 12-lead ECG: early diagnosis of acute myocardial infarction*, European Heart Journal (2001) 22, 218–227. [online]. 2001 [cit 2013-11-6] Dostupné z: <http://eurheartj.oxfordjournals.org/content/22/3/218.full.pdf>

- [20] KOLÁŘOVÁ, J., FIALOVÁ, K., JANOUŠEK, O., NOVÁKOVÁ, M., PROVAZNÍK, I.: *Experimental Methods for Simultaneous Measurement of Action Potentials and Electrograms in Isolated Heart*, *Physiol. Res.* 59 (Suppl. 1), 2010, 10 s.
- [21] KOLÁŘOVÁ, J., JANOUŠEK, O., NOVÁKOVÁ, M., FIALOVÁ, K., PROVAZNÍK, I.: *Influence of ischemia on left ventricular depolarization in isolated rabbit hearts perfused according to Langendorff*, *IFMBE Proceeding*, Volume 25, World Congress on Medical Physics and Biomedical Engineering, 2009, 4 s.
- [22] JANOUŠEK, O., KOLÁŘOVÁ, J., NOVÁKOVÁ, M., PROVAZNÍK, I.: *Three-Dimensional Electrogram in Spherical Coordinates: Application to Ischemia Analysis*, *Physiol. Res.* 59 (Suppl. 1), 2010, 8 s.
- [23] DUDA, R. O., HART, P. E., STORK, D. G., *Pattern classification, 2nd Edition*, Wiley, 2000, 680 s. ISBN: 978-0-471-05669-0
- [24] LLAMENDO, M., MARTINEZ, J. P., *Heartbeat Classification Using Feature Selection Driven by Database Generalization Criteria*, *IEEE Transactions on Biomedical Engineering*, 2011
- [25] DRANCA, L., GONI, A., ILLARRAMENDI, A., *Tuning a Real-Time Detector of Transient Cardiac Ischemic Episodes on the Long-Term ST Database According to the Annotation Protocol B*, *Computing in Cardiology Conference*, 2013
- [26] LLAMENDO, M., MARTINEZ, J. P., ALBERTAL, M., ROMERO, D., PUEYO, E., LAGUNA, P., *Morphological Features of the ECG for Detection of Stress-Induced Ischemia*, *Computing in Cardiology Conference*, 2013

## Seznam příloh


**Příloha č. 1:** EKG průběhy (svody Y a Z)

**Příloha č. 2:** Krabicové grafy vypočtených parametrů (svody Y a Z)


**Příloha č. 3:** Korelační matice parametrů (svody Y a Z)

**Příloha č. 4:** Ukazatele úspěšnosti klasifikace – parametry získané analýzou hlavních komponent


## Příloha č. 1: EKG průběhy (svody Y a Z)




kontrola (svod Y)



kontrola (svod Z)



ischemie (svod Y)




ischemie (svod Z)


Obrázek: EKG průběhy – svody Y a Z




## Příloha č. 2: Krabicové grafy vypočtených parametrů (svod Y a Z)




Obrázek: Krabicový graf parametru JTamp (svod Y)




Obrázek: Krabicový graf parametru Tamp (svod Y)




Obrázek: Krabicové grafy parametrů ST10, ST20, ST30, ST40 a ST50 (svod Y)




Obrázek: Krabicové grafy parametrů AUCqrst, AUCqrs, +AUCqrs a -AUCqrs (svod Y)




Obrázek: Krabicové grafy parametrů AUCsTamp a AUCsTampTend (svod Y)




Obrázek: Krabicové grafy parametrů  $\pm AUC_{qrs}$  a  $sTamp/TampTendAUC_y$  (svod Y)




Obrázek: Krabicové grafy parametrů  $CEAggrad\ \beta$ ,  $CEAgqs\ \beta$  a  $CEAst-t\ \beta$




Obrázek: Krabicový graf parametru  $CEAlenght\ qj$




Obrázek: Krabicový graf parametru JTamp (svod Z)




Obrázek: Krabicový graf parametru Tamp (svod Z)




Obrázek: Krabicové grafy parametrů ST10, ST20, ST30, ST40 a ST50 (svod Z)




Obrázek: Krabicové grafy parametrů AUCqrst, AUCqrs, +AUCqrs a -AUCqrs (svod Z)




Obrázek: Krabicové grafy parametrů AUCsTamp a AUCTampTend (svod Z)



Obrázek: Krabicové grafy parametrů +/-AUCqrs a sTamp/TampTendAUC (svod Z)



Obrázek: Krabicové grafy parametrů CEAggrad  $\gamma$ , CEAgqr  $\gamma$  a CEAst-t  $\gamma$



Obrázek: Krabicový graf parametru CEAlenght jt

Příloha č. 3: Korelační matice parametrů (svody Y a Z)

Tabulka: Korelační matice – kontrolní fáze – svod Y

	CEAlen gth y	CEAst-t y	CEAqrs y	CEAgr ad y	sTamp/ TampT endAU C y	AUCTa mpTen d y	AUCsT amp y	+/- AUCqr s y	- AUCqr s y	+AUCq rs y	AUCst- t y	AUCqr s y	AUCqr st y	Tamp y	ST50 y	ST40 y	ST30 y	ST20 y	ST10 y	JTamp y
JTamp y	0,038	0,204	0,038	0,083	0,169	-0,107	-0,225	-0,125	-0,277	-0,088	-0,202	-0,254	-0,230	-0,237	-0,277	-0,236	-0,197	-0,125	-0,071	<b>1,000</b>
ST10 y	-0,301	0,625	0,289	0,667	0,098	0,678	0,634	0,203	0,370	0,145	0,654	0,346	0,666	0,404	0,765	<b>0,800</b>	<b>0,892</b>	<b>0,925</b>	<b>1,000</b>	-0,071
ST20 y	-0,245	0,578	0,284	0,658	0,109	0,767	0,754	0,264	0,334	0,187	0,770	0,330	0,772	0,545	<b>0,859</b>	<b>0,932</b>	<b>0,939</b>	<b>1,000</b>	<b>0,925</b>	-0,125
ST30 y	-0,166	0,506	0,321	0,603	0,137	<b>0,834</b>	<b>0,861</b>	0,323	0,343	0,236	<b>0,870</b>	0,353	<b>0,868</b>	0,688	<b>0,962</b>	<b>0,963</b>	<b>1,000</b>	<b>0,939</b>	<b>0,892</b>	-0,197
ST40 y	-0,084	0,426	0,351	0,527	0,160	<b>0,853</b>	<b>0,907</b>	0,369	0,343	0,273	<b>0,910</b>	0,364	<b>0,908</b>	0,764	<b>0,972</b>	<b>1,000</b>	<b>0,963</b>	<b>0,932</b>	<b>0,800</b>	-0,236
ST50 y	-0,013	0,382	0,387	0,480	0,181	<b>0,862</b>	<b>0,939</b>	0,389	0,361	0,292	<b>0,938</b>	0,385	<b>0,938</b>	<b>0,830</b>	<b>1,000</b>	<b>0,972</b>	<b>0,962</b>	<b>0,859</b>	0,765	-0,277
Tamp y	0,368	0,244	0,505	0,295	0,197	<b>0,826</b>	<b>0,926</b>	0,310	0,300	0,232	<b>0,922</b>	0,318	<b>0,911</b>	<b>1,000</b>	<b>0,830</b>	0,764	0,688	0,545	0,404	-0,237
AUCqrst y	0,148	0,335	0,550	0,398	0,205	<b>0,900</b>	<b>0,991</b>	0,443	0,457	0,350	<b>0,988</b>	0,481	<b>1,000</b>	<b>0,911</b>	<b>0,938</b>	<b>0,908</b>	<b>0,868</b>	0,772	0,666	-0,230
AUCqrs y	0,035	0,133	0,614	0,121	0,342	0,156	0,388	0,740	<b>0,965</b>	0,704	0,341	<b>1,000</b>	0,481	0,318	0,385	0,364	0,353	0,330	0,346	-0,254
AUCst-t y	0,153	0,336	0,482	0,406	0,161	<b>0,937</b>	<b>0,995</b>	0,346	0,322	0,253	<b>1,000</b>	0,341	<b>0,988</b>	<b>0,922</b>	<b>0,938</b>	<b>0,910</b>	<b>0,870</b>	0,770	0,654	-0,202
+AUCqrs y	0,302	0,092	0,670	0,057	0,397	0,034	0,313	<b>0,982</b>	0,494	<b>1,000</b>	0,253	0,704	0,350	0,232	0,292	0,273	0,236	0,187	0,145	-0,088
-AUCqrs y	-0,071	0,130	0,504	0,127	0,272	0,176	0,358	0,545	<b>1,000</b>	0,494	0,322	<b>0,965</b>	0,457	0,300	0,361	0,343	0,343	0,334	0,370	-0,277
+/-AUCqrs y	0,273	0,059	0,675	0,042	0,401	0,121	0,405	<b>1,000</b>	0,545	<b>0,982</b>	0,346	0,740	0,443	0,310	0,389	0,369	0,323	0,264	0,203	-0,125
AUCsTamp y	0,195	0,312	0,530	0,378	0,218	<b>0,896</b>	<b>1,000</b>	0,405	0,358	0,313	<b>0,995</b>	0,388	<b>0,991</b>	<b>0,926</b>	<b>0,939</b>	<b>0,907</b>	<b>0,861</b>	0,754	0,634	-0,225
AUCTampTend y	-0,011	0,390	0,283	0,470	-0,047	<b>1,000</b>	<b>0,896</b>	0,121	0,176	0,034	<b>0,937</b>	0,156	<b>0,900</b>	<b>0,826</b>	<b>0,862</b>	<b>0,853</b>	<b>0,834</b>	0,767	0,678	-0,107
sTamp/TampTendAUC y	0,331	0,066	0,507	-0,007	<b>1,000</b>	-0,047	0,218	0,401	0,272	0,397	0,161	0,342	0,205	0,197	0,181	0,160	0,137	0,109	0,098	0,169
CEAgrad y	-0,175	<b>0,950</b>	0,129	<b>1,000</b>	-0,007	0,470	0,378	0,042	0,127	0,057	0,406	0,121	0,398	0,295	0,480	0,527	0,603	0,658	0,667	0,083
CEAqrs y	0,651	0,240	<b>1,000</b>	0,129	0,507	0,283	0,530	0,675	0,504	0,670	0,482	0,614	0,550	0,505	0,387	0,351	0,321	0,284	0,289	0,038
CEAst-t y	-0,054	<b>1,000</b>	0,240	<b>0,950</b>	0,066	0,390	0,312	0,059	0,130	0,092	0,336	0,133	0,335	0,244	0,382	0,426	0,506	0,578	0,625	0,204
CEAlength y	<b>1,000</b>	-0,054	0,651	-0,175	0,331	-0,011	0,195	0,273	-0,071	0,302	0,153	0,035	0,148	0,368	-0,013	-0,084	-0,166	-0,245	-0,301	0,038

	CEAlen gth z	CEAst- z	CEAqrs z	CEAgr ad z	sTamp/ TampT endAUC z	AUCTa mpTend z	AUCsT amp z	+/- AUCqrs z	- AUCqrs z	+AUCq rs z	AUCst- t z	AUCqrs z	AUCqrs st z	Tamp z	ST50 z	ST40 z	ST30 z	ST20 z	ST10 z	JTamp z
JTamp z	-0,526	0,375	-0,275	0,408	0,016	0,298	0,570	0,263	0,123	0,266	0,541	0,180	0,541	0,734	0,504	0,511	0,523	0,517	0,500	<b>1,000</b>
ST10 z	-0,293	0,191	-0,228	0,558	0,008	0,379	0,703	0,555	0,303	0,572	0,668	0,419	0,708	0,656	<b>0,840</b>	<b>0,827</b>	<b>0,897</b>	<b>0,897</b>	<b>1,000</b>	0,500
ST20 z	-0,441	0,414	-0,267	0,490	0,003	0,553	0,784	0,534	0,110	0,558	0,780	0,250	0,779	0,704	<b>0,898</b>	<b>0,969</b>	<b>0,938</b>	<b>1,000</b>	<b>0,897</b>	0,517
ST30 z	-0,528	0,487	-0,274	0,475	0,001	0,610	<b>0,822</b>	0,467	0,028	0,504	<b>0,826</b>	0,165	<b>0,805</b>	0,729	<b>0,974</b>	<b>0,949</b>	<b>1,000</b>	<b>0,938</b>	<b>0,897</b>	0,523
ST40 z	-0,541	0,505	-0,303	0,447	-0,004	0,642	<b>0,820</b>	0,431	0,011	0,453	<b>0,833</b>	0,136	<b>0,806</b>	0,718	<b>0,951</b>	<b>1,000</b>	<b>0,949</b>	<b>0,969</b>	<b>0,827</b>	0,511
ST50 z	-0,571	0,507	-0,298	0,447	-0,008	0,653	<b>0,833</b>	0,368	-0,006	0,393	<b>0,847</b>	0,105	<b>0,813</b>	0,726	<b>1,000</b>	<b>0,951</b>	<b>0,974</b>	<b>0,898</b>	<b>0,840</b>	0,504
Tamp z	-0,521	0,563	-0,477	0,617	-0,029	0,592	<b>0,916</b>	0,532	0,281	0,515	<b>0,899</b>	0,385	<b>0,917</b>	<b>1,000</b>	0,726	0,718	0,729	0,704	0,656	0,734
AUCqrst z	-0,454	0,551	-0,491	0,642	-0,015	0,718	<b>0,977</b>	0,612	0,295	0,586	<b>0,981</b>	0,416	<b>1,000</b>	<b>0,917</b>	<b>0,813</b>	<b>0,806</b>	<b>0,805</b>	0,779	0,708	0,541
AUCqrs z	0,336	-0,255	-0,439	0,644	0,013	-0,086	0,317	0,737	<b>0,967</b>	0,625	0,231	<b>1,000</b>	0,416	0,385	0,105	0,136	0,165	0,250	0,419	0,180
AUCst-t z	-0,558	0,644	-0,431	0,549	-0,019	0,787	<b>0,977</b>	0,497	0,108	0,493	<b>1,000</b>	0,231	<b>0,981</b>	<b>0,899</b>	<b>0,847</b>	<b>0,833</b>	<b>0,826</b>	0,780	0,668	0,541
+AUCqrs z	0,064	0,172	-0,090	0,465	-0,006	0,206	0,544	<b>0,969</b>	0,404	<b>1,000</b>	0,493	0,625	0,586	0,515	0,393	0,453	0,504	0,558	0,572	0,266
-AUCqrs z	0,374	-0,356	-0,485	0,602	0,017	-0,169	0,192	0,545	<b>1,000</b>	0,404	0,108	<b>0,967</b>	0,295	0,281	-0,006	0,011	0,028	0,110	0,303	0,123
+/-AUCqrs z	0,088	0,152	-0,222	0,519	0,000	0,205	0,550	<b>1,000</b>	0,545	<b>0,969</b>	0,497	0,737	0,612	0,532	0,368	0,431	0,467	0,534	0,555	0,263
AUCsTamp z	-0,524	0,597	-0,432	0,595	-0,014	0,638	<b>1,000</b>	0,550	0,192	0,544	<b>0,977</b>	0,317	<b>0,977</b>	<b>0,916</b>	<b>0,833</b>	<b>0,820</b>	<b>0,822</b>	0,784	0,703	0,570
AUCTampTend z	-0,498	0,600	-0,306	0,260	-0,028	<b>1,000</b>	0,638	0,205	-0,169	0,206	0,787	-0,086	0,718	0,592	0,653	0,642	0,610	0,553	0,379	0,298
sTamp/TampTendAUC z	0,035	-0,021	-0,021	-0,008	<b>1,000</b>	-0,028	-0,014	0,000	0,017	-0,006	-0,019	0,013	-0,015	-0,029	-0,008	-0,004	0,001	0,003	0,008	0,016
CEAgrad z	-0,146	0,042	-0,618	<b>1,000</b>	-0,008	0,260	0,595	0,519	0,602	0,465	0,549	0,644	0,642	0,617	0,447	0,447	0,475	0,490	0,558	0,408
CEAqrs z	0,164	-0,172	<b>1,000</b>	-0,618	-0,021	-0,306	-0,432	-0,222	-0,485	-0,090	-0,431	-0,439	-0,491	-0,477	-0,298	-0,303	-0,274	-0,267	-0,228	-0,275
CEAst-t z	-0,713	<b>1,000</b>	-0,172	0,042	-0,021	0,600	0,597	0,152	-0,356	0,172	0,644	-0,255	0,551	0,563	0,507	0,505	0,487	0,414	0,191	0,375
CEAlength z	<b>1,000</b>	-0,713	0,164	-0,146	0,035	-0,498	-0,524	0,088	0,374	0,064	-0,558	0,336	-0,454	-0,521	-0,571	-0,541	-0,528	-0,441	-0,293	-0,526

Tabulka: Korelační matice – kontrolní fáze – svod Z



	CEAlen ght y	CEAst- y	CEAqrs y	CEAgr ad y	sTamp/ TampT endAUC y	AUCTa mpTen d y	AUCsT amp y	+/- AUCqr s y	- AUCqr s y	+AUCq rs y	AUCst- t y	AUCqr s y	AUCqr st y	Tamp y	ST50 y	ST40 y	ST30 y	ST20 y	ST10 y	JTamp y
JTamp y	0,045	0,158	0,495	0,227	-0,021	-0,083	0,388	0,005	0,556	-0,012	0,195	0,338	0,379	0,585	-0,115	0,016	0,104	0,107	0,036	<b>1,000</b>
ST10 y	0,560	0,140	0,267	0,199	-0,027	0,068	0,327	0,415	0,275	0,561	0,259	0,501	0,539	0,676	0,266	0,422	0,609	<b>0,860</b>	<b>1,000</b>	0,036
ST20 y	0,469	0,455	-0,010	0,429	-0,046	0,305	0,599	0,343	0,030	0,391	0,587	0,249	0,618	0,521	0,654	<b>0,801</b>	<b>0,909</b>	<b>1,000</b>	<b>0,860</b>	0,107
ST30 y	0,336	0,628	-0,252	0,541	-0,056	0,431	0,711	0,234	-0,200	0,197	0,739	-0,008	0,558	0,313	<b>0,877</b>	<b>0,962</b>	<b>1,000</b>	<b>0,909</b>	0,609	0,104
ST40 y	0,258	0,681	-0,426	0,548	-0,061	0,504	0,709	0,161	-0,381	0,082	0,784	-0,188	0,471	0,141	<b>0,959</b>	<b>1,000</b>	<b>0,962</b>	<b>0,801</b>	0,422	0,016
ST50 y	0,218	0,693	-0,554	0,531	-0,062	0,573	0,661	0,098	-0,527	0,015	0,799	-0,318	0,393	-0,023	<b>1,000</b>	<b>0,959</b>	<b>0,877</b>	0,654	0,266	-0,115
Tamp y	0,413	0,092	0,495	0,166	-0,051	-0,049	0,391	0,313	0,520	0,376	0,225	0,544	0,543	<b>1,000</b>	-0,023	0,141	0,313	0,521	0,676	0,585
AUCqrst y	0,608	0,374	0,430	0,322	-0,027	0,461	0,663	0,460	0,443	0,633	0,732	0,647	<b>1,000</b>	0,543	0,393	0,471	0,558	0,618	0,539	0,379
AUCqrs y	0,605	-0,225	<b>0,865</b>	-0,077	0,033	-0,201	0,132	0,509	<b>0,837</b>	<b>0,818</b>	-0,045	<b>1,000</b>	0,647	0,544	-0,318	-0,188	-0,008	0,249	0,501	0,338
AUCst-t y	0,257	0,692	-0,209	0,491	-0,064	0,783	0,751	0,149	-0,167	0,099	<b>1,000</b>	-0,045	0,732	0,225	0,799	0,784	0,739	0,587	0,259	0,195
+AUCqrs y	0,698	-0,015	0,441	0,023	0,017	-0,096	0,254	0,680	0,370	<b>1,000</b>	0,099	<b>0,818</b>	0,633	0,376	0,015	0,082	0,197	0,391	0,561	-0,012
-AUCqrs y	0,313	-0,350	<b>0,978</b>	-0,146	0,036	-0,233	-0,027	0,175	<b>1,000</b>	0,370	-0,167	<b>0,837</b>	0,443	0,520	-0,527	-0,381	-0,200	0,030	0,275	0,556
+/-AUCqrs y	0,441	0,029	0,207	0,030	-0,005	-0,064	0,300	<b>1,000</b>	0,175	0,680	0,149	0,509	0,460	0,313	0,098	0,161	0,234	0,343	0,415	0,005
AUCsTamp y	0,524	0,480	-0,061	0,327	-0,054	0,178	<b>1,000</b>	0,300	-0,027	0,254	0,751	0,132	0,663	0,391	0,661	0,709	0,711	0,599	0,327	0,388
AUCTampTend y	-0,113	0,580	-0,264	0,423	-0,045	<b>1,000</b>	0,178	-0,064	-0,233	-0,096	0,783	-0,201	0,461	-0,049	0,573	0,504	0,431	0,305	0,068	-0,083
sTamp/TampTendAUC y	-0,005	-0,054	0,044	-0,019	<b>1,000</b>	-0,045	-0,054	-0,005	0,036	0,017	-0,064	0,033	-0,027	-0,051	-0,062	-0,061	-0,056	-0,046	-0,027	-0,021
CEAgrad y	-0,003	0,608	-0,114	<b>1,000</b>	-0,019	0,423	0,327	0,030	-0,146	0,023	0,491	-0,077	0,322	0,166	0,531	0,548	0,541	0,429	0,199	0,227
CEAqrs y	0,357	-0,386	<b>1,000</b>	-0,114	0,044	-0,264	-0,061	0,207	<b>0,978</b>	0,441	-0,209	<b>0,865</b>	0,430	0,495	-0,554	-0,426	-0,252	-0,010	0,267	0,495
CEAst-t y	-0,009	<b>1,000</b>	-0,386	0,608	-0,054	0,580	0,480	0,029	-0,350	-0,015	0,692	-0,225	0,374	0,092	0,693	0,681	0,628	0,455	0,140	0,158
CEAlenght y	<b>1,000</b>	-0,009	0,357	-0,003	-0,005	-0,113	0,524	0,441	0,313	0,698	0,257	0,605	0,608	0,413	0,218	0,258	0,336	0,469	0,560	0,045

Tabulka: Korelační matice – ischemická fáze – svod Y

	CEAlenght z	CEAst-t z	CEAqrs z	CEAgrad z	sTamp/TampTendAUC z	AUCTampTend z	AUCsTamp z	+/- AUCqrs z	- AUCqrs z	+AUCqrs z	AUCst-t z	AUCqrs z	AUCqrs z	Tamp z	ST50 z	ST40 z	ST30 z	ST20 z	ST10 z	JTamp z
JTamp z	-0,308	0,237	-0,019	0,224	0,116	0,024	0,020	0,011	0,326	0,025	0,023	0,259	0,052	0,023	-0,104	-0,103	-0,108	-0,126	-0,181	<b>1,000</b>
ST10 z	0,438	0,346	0,624	0,509	-0,086	<b>0,890</b>	<b>0,829</b>	0,097	0,515	0,492	<b>0,889</b>	0,548	<b>0,881</b>	<b>0,857</b>	<b>0,935</b>	<b>0,946</b>	<b>0,960</b>	<b>0,978</b>	<b>1,000</b>	-0,181
ST20 z	0,294	0,423	0,647	0,565	-0,091	<b>0,933</b>	<b>0,886</b>	0,143	0,531	0,462	<b>0,942</b>	0,551	<b>0,930</b>	<b>0,887</b>	<b>0,982</b>	<b>0,990</b>	<b>0,995</b>	<b>1,000</b>	<b>0,978</b>	-0,126
ST30 z	0,249	0,440	0,659	0,578	-0,092	<b>0,943</b>	<b>0,901</b>	0,173	0,541	0,457	<b>0,955</b>	0,557	<b>0,943</b>	<b>0,896</b>	<b>0,994</b>	<b>0,997</b>	<b>1,000</b>	<b>0,995</b>	<b>0,960</b>	-0,108
ST40 z	0,233	0,445	0,668	0,581	-0,093	<b>0,944</b>	<b>0,902</b>	0,187	0,547	0,453	<b>0,956</b>	0,561	<b>0,944</b>	<b>0,901</b>	<b>0,998</b>	<b>1,000</b>	<b>0,997</b>	<b>0,990</b>	<b>0,946</b>	-0,103
ST50 z	0,227	0,458	0,675	0,595	-0,093	<b>0,943</b>	<b>0,903</b>	0,207	0,555	0,457	<b>0,956</b>	0,568	<b>0,945</b>	<b>0,908</b>	<b>1,000</b>	<b>0,998</b>	<b>0,994</b>	<b>0,982</b>	<b>0,935</b>	-0,104
Tamp z	0,377	0,502	0,691	0,698	-0,150	<b>0,895</b>	<b>0,918</b>	0,325	0,723	0,562	<b>0,944</b>	0,730	<b>0,954</b>	<b>1,000</b>	<b>0,908</b>	<b>0,901</b>	<b>0,896</b>	<b>0,887</b>	<b>0,857</b>	0,023
AUCqrst z	0,251	0,497	0,706	0,666	-0,101	<b>0,946</b>	<b>0,968</b>	0,315	0,710	0,568	<b>0,996</b>	0,722	<b>1,000</b>	<b>0,954</b>	<b>0,945</b>	<b>0,944</b>	<b>0,943</b>	<b>0,930</b>	<b>0,881</b>	0,052
AUCqrs z	0,379	0,366	0,704	0,567	-0,007	0,627	0,634	0,510	<b>0,973</b>	<b>0,814</b>	0,657	<b>1,000</b>	0,722	0,730	0,568	0,561	0,557	0,551	0,548	0,259
AUCst-t z	0,224	0,494	0,678	0,653	-0,109	<b>0,949</b>	<b>0,972</b>	0,277	0,647	0,513	<b>1,000</b>	0,657	<b>0,996</b>	<b>0,944</b>	<b>0,956</b>	<b>0,956</b>	<b>0,955</b>	<b>0,942</b>	<b>0,889</b>	0,023
+AUCqrs z	0,497	0,121	0,714	0,311	0,076	0,495	0,492	0,529	0,658	<b>1,000</b>	0,513	<b>0,814</b>	0,568	0,562	0,457	0,453	0,457	0,462	0,492	0,025
-AUCqrs z	0,293	0,428	0,628	0,612	-0,039	0,617	0,627	0,451	<b>1,000</b>	0,658	0,647	<b>0,973</b>	0,710	0,723	0,555	0,547	0,541	0,531	0,515	0,326
+/-AUCqrs z	0,122	0,062	0,511	0,191	-0,016	0,228	0,295	<b>1,000</b>	0,451	0,529	0,277	0,510	0,315	0,325	0,207	0,187	0,173	0,143	0,097	0,011
AUCsTamp z	0,202	0,453	0,666	0,618	-0,144	<b>0,848</b>	<b>1,000</b>	0,295	0,627	0,492	<b>0,972</b>	0,634	<b>0,968</b>	<b>0,918</b>	<b>0,903</b>	<b>0,902</b>	<b>0,901</b>	<b>0,886</b>	<b>0,829</b>	0,020
AUCTampTend z	0,232	0,505	0,633	0,640	-0,051	<b>1,000</b>	<b>0,848</b>	0,228	0,617	0,495	<b>0,949</b>	0,627	<b>0,946</b>	<b>0,895</b>	<b>0,943</b>	<b>0,944</b>	<b>0,943</b>	<b>0,933</b>	<b>0,890</b>	0,024
sTamp/TampTendAUC z	0,020	-0,189	-0,002	-0,139	<b>1,000</b>	-0,051	-0,144	-0,016	-0,039	0,076	-0,109	-0,007	-0,101	-0,150	-0,093	-0,093	-0,092	-0,091	-0,086	0,116
CEAgrad z	-0,018	<b>0,913</b>	0,313	<b>1,000</b>	-0,139	0,640	0,618	0,191	0,612	0,311	0,653	0,567	0,666	0,698	0,595	0,581	0,578	0,565	0,509	0,224
CEAqrs z	0,314	0,176	<b>1,000</b>	0,313	-0,002	0,633	0,666	0,511	0,628	0,714	0,678	0,704	0,706	0,691	0,675	0,668	0,659	0,647	0,624	-0,019
CEAst-t z	-0,257	<b>1,000</b>	0,176	<b>0,913</b>	-0,189	0,505	0,453	0,062	0,428	0,121	0,494	0,366	0,497	0,502	0,458	0,445	0,440	0,423	0,346	0,237
CEAlenght z	<b>1,000</b>	-0,257	0,314	-0,018	0,020	0,232	0,202	0,122	0,293	0,497	0,224	0,379	0,251	0,377	0,227	0,233	0,249	0,294	0,438	-0,308

Tabulka: Korelační matice – ischemická fáze – svod Z

## Příloha č. 4: Ukazatele úspěšnosti klasifikace

### 3 hlavní komponenty

Tabulka: Ukazatele úspěšnosti klasifikace [%] pro různý počet epoch učení a neuronů ve skryté vrstvě (traingd)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	66,2	84,3	75,1	77,9	88,5	82,5	76,1	87,5	79,7	74,4	86,1	79,6
50	82,8	93,6	82,8	79,1	92,3	85,3	84,1	91,6	84,1	83,7	90,0	86,2
100	81,4	90,8	85,9	81,4	92,4	87,6	84,8	91,5	87,9	85,4	92,3	88,5
200	83,0	92,1	87,6	83,9	92,6	88,1	89,4	92,6	89,4	89,0	94,1	91,4
300	84,0	93,0	88,4	85,6	92,0	88,8	88,0	92,5	90,1	91,2	94,0	92,5

(traingda)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	80,1	74,1	76,1	81,2	88,4	83,4	79,9	90,8	85,1	78,9	85,6	78,8
50	86,7	78,6	81,3	84,5	93,0	88,7	83,2	92,5	87,7	83,0	91,1	86,5
100	85,0	92,8	88,5	86,3	93,1	89,7	87,4	92,9	90,0	85,8	92,8	88,9
200	88,5	91,4	89,8	90,3	93,8	92,0	90,1	92,5	91,3	90,0	93,4	91,5
300	89,1	92,7	90,8	91,7	92,9	92,3	91,0	94,6	92,7	91,6	93,7	92,5

### 5 hlavních komponent

Tabulka: Ukazatele úspěšnosti klasifikace [%] pro různý počet epoch učení a neuronů ve skryté vrstvě (traingd)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	62,2	81,6	71,8	76,1	86,2	80,6	72,7	85,8	78,4	82,3	92,8	85,6
50	79,5	92,7	86,0	84,8	92,5	88,4	86,6	95,5	90,2	88,8	95,8	91,6
100	85,7	94,4	90,0	89,4	95,4	92,1	91,7	95,8	93,4	91,7	96,2	93,3
200	88,6	95,7	92,0	92,2	96,1	93,9	92,8	95,8	93,9	96,0	96,9	<b>95,9</b>
300	91,1	96,0	93,4	94,7	96,6	<b>95,3</b>	95,0	97,0	<b>95,8</b>	96,9	97,5	<b>96,8</b>

(traingda)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	74,5	89,6	82,1	82,9	91,8	86,8	83,7	96,3	88,7	83,1	92,6	86,6
50	87,2	95,4	91,2	92,7	96,0	94,0	89,7	95,9	92,4	89,7	94,8	91,6
100	94,7	95,9	<b>95,5</b>	93,9	96,3	94,9	93,9	96,7	94,8	92,7	96,0	93,7
200	95,5	96,8	<b>96,1</b>	95,6	96,4	<b>95,8</b>	95,8	97,0	<b>96,2</b>	95,4	97,6	<b>96,1</b>
300	95,6	96,8	<b>96,0</b>	96,8	97,5	<b>97,0</b>	97,1	98,1	<b>97,3</b>	97,3	97,4	<b>97,1</b>

## 7 hlavních komponent

Tabulka: Ukazatele úspěšnosti klasifikace [%] pro různý počet epoch učení a neuronů ve skryté vrstvě (traingd)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	71,1	85,4	78,2	70,0	81,1	75,0	77,7	93,9	85,3	84,5	94,5	88,6
50	83,2	95,2	89,1	86,2	94,7	90,2	88,4	95,8	91,4	90,4	95,9	92,8
100	86,0	95,8	90,8	88,1	96,8	92,3	92,7	98,4	<b>95,3</b>	94,0	97,8	<b>95,6</b>
200	90,6	97,7	94,1	93,4	97,0	<b>95,1</b>	94,9	98,2	<b>96,2</b>	96,6	98,3	<b>97,1</b>
300	93,0	97,8	<b>95,3</b>	94,9	98,6	<b>96,7</b>	96,0	98,5	<b>97,0</b>	97,8	99,0	<b>98,2</b>

(traigda)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	76,3	91,3	83,6	79,9	89,8	84,7	84,3	97,7	90,5	84,3	94,0	88,1
50	87,2	97,1	92,0	92,2	97,3	94,6	92,0	97,0	94,3	88,9	96,7	92,2
100	95,5	98,0	<b>96,9</b>	95,2	97,8	<b>96,4</b>	95,7	98,6	<b>96,9</b>	94,5	98,0	<b>95,9</b>
200	98,1	98,4	<b>98,2</b>	97,1	98,4	<b>97,6</b>	97,8	98,9	<b>98,2</b>	97,3	98,7	<b>97,8</b>
300	98,5	98,6	<b>98,6</b>	98,5	98,8	<b>98,5</b>	98,9	99,2	<b>98,9</b>	98,4	99,2	<b>98,7</b>

## 8 hlavních komponent

Tabulka: Ukazatele úspěšnosti klasifikace [%] pro různý počet epoch učení a neuronů ve skryté vrstvě (traingd)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	62,2	79,0	70,5	74,0	83,7	78,6	77,3	90,9	83,4	82,3	92,9	86,6
50	76,7	91,8	84,1	84,0	95,3	89,5	84,7	97,2	90,4	89,9	97,3	93,0
100	83,8	95,3	89,4	89,4	97,1	93,2	90,6	97,3	93,7	93,1	97,4	94,8
200	88,5	96,9	92,6	93,8	98,3	<b>95,8</b>	93,9	97,9	<b>95,6</b>	96,2	98,2	<b>97,0</b>
300	92,4	97,4	<b>95,0</b>	94,6	97,7	<b>96,0</b>	95,8	98,0	<b>96,6</b>	98,2	99,0	<b>98,4</b>

(traingda)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	74,7	89,1	81,7	83,1	92,0	87,2	81,0	92,3	85,7	83,0	90,5	85,4
50	89,7	96,1	92,9	92,5	97,2	94,8	88,4	97,5	93,2	90,9	95,3	92,5
100	95,5	98,5	<b>96,9</b>	95,3	98,0	<b>96,5</b>	93,9	97,9	<b>95,6</b>	93,4	97,8	<b>95,2</b>
200	97,6	98,8	<b>98,2</b>	96,8	98,1	<b>97,3</b>	96,8	98,5	<b>97,5</b>	96,8	98,6	<b>97,6</b>
300	98,4	99,3	<b>98,8</b>	98,8	99,4	<b>99,0</b>	97,3	99,0	<b>98,0</b>	97,9	98,8	<b>98,2</b>

## 9 hlavních komponent

Tabulka: Ukazatele úspěšnosti klasifikace [%] pro různý počet epoch učení a neuronů ve skryté vrstvě (traingd)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	68,1	87,3	77,7	73,2	86,5	79,4	78,0	89,3	83,0	81,4	93,6	86,7
50	77,1	91,2	84,1	83,5	93,6	88,4	85,7	96,0	90,3	89,9	97,3	92,0
100	84,3	96,7	90,3	89,3	96,5	92,7	91,6	97,6	94,3	93,4	97,3	<b>95,0</b>
200	89,6	96,8	93,1	92,9	97,3	<b>95,0</b>	95,0	98,2	<b>96,4</b>	97,3	99,0	<b>97,9</b>
300	93,2	97,5	<b>95,3</b>	96,4	98,4	<b>97,3</b>	96,8	98,7	<b>97,6</b>	98,0	98,7	<b>98,2</b>

(traingda)

Počet epoch učení	Počet neuronů ve skryté vrstvě											
	10			20			30			50		
	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp	Se	Sp	Úsp
20	73,0	88,0	80,5	78,2	94,6	86,3	86,5	95,3	90,5	80,9	94,9	86,3
50	90,4	97,2	93,7	93,6	97,4	<b>95,6</b>	91,7	96,4	93,9	90,3	96,5	92,7
100	95,8	98,3	<b>97,0</b>	95,4	98,0	<b>96,6</b>	94,2	97,9	<b>95,9</b>	92,7	98,1	<b>95,1</b>
200	97,9	98,5	<b>98,1</b>	97,7	98,9	<b>98,2</b>	97,9	98,6	<b>98,0</b>	97,5	98,5	<b>97,9</b>
300	98,6	98,8	<b>98,6</b>	98,6	99,0	<b>98,7</b>	98,6	99,1	<b>98,8</b>	98,1	98,9	<b>98,3</b>

### **Přiložené CD obsahuje:**

- Program pro výpočet parametrů EKG - *parametryEKG.m*
- Neronová síť(všechny parametry) - *sit\_vsechny.m*
- Neronová síť(PCA parametry) - *sit\_pca.m*
- Elektronická verze diplomové práce - *pavel\_tichy\_DP.pdf*

Všechny programy byly vytvořeny v Matlabu verze 2010b a vyžadují mít nainstalované následující toolboxy: *Statistics Toolbox* a *Neural Network Toolbox*.